



UNIVERSIDADE FEDERAL DOS VALES DO JEQUITINHONHA E MUCURI

Programa de Pós-Graduação em Ciência Florestal

Eduardo Pelli

**MAPEAMENTO DO POTENCIAL MADEIREIRO EM ÁREA DE FLORESTA
AMAZÔNICA**

Diamantina

2019

Eduardo Pelli

**MAPEAMENTO DO POTENCIAL MADEIREIRO EM ÁREA DE FLORESTA
AMAZÔNICA**

Tese de Doutorado apresentada ao programa de Pós-graduação em Ciência Florestal da Universidade Federal dos Vales do Jequitinhonha e Mucuri, como requisito para obtenção do título de Doutor.

Orientador: Prof. Dr. Eric Bastos Görgens

Diamantina

2019

Elaborado com os dados fornecidos pelo(a) autor(a).

P391m

Pelli, Eduardo

Mapeamento do potencial madeireiro em área de floresta amazônica / Eduardo Pelli, 2019.

93 p. : il.

Orientador: Eric Bastos Görgens

Tese (Doutorado – Programa de Pós-Graduação em Ciência Florestal) - Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina, 2019.

1. LiDAR. 2. Visão computacional. 3. Manejo florestal de precisão. I. Görgens, Eric Bastos. II. Título. III. Universidade Federal dos Vales do Jequitinhonha e Mucuri.

CDD 634.92

Ficha Catalográfica – Serviço de Bibliotecas/UFVJM
Bibliotecária Nádia Santos Barbosa - CRB6/3468

**Mapeamento do potencial madeireiro em área de floresta
amazônica**

Tese apresentada ao DOUTORADO
EM CIÊNCIA FLORESTAL, nível de
DOUTORADO como parte dos
requisitos para obtenção do título de
DOUTOR EM CIÊNCIA FLORESTAL

Orientador (a): Prof. Dr. Eric Bastos
Gorgens

Data da aprovação : 14/03/2019



Prof.Dr. ERIC BASTOS GORGENS - UFVJM



Prof.Dr. GILCIANO SARAIVA NOGUEIRA - UFVJM



Prof.Dr. CRISTIANO CHRISTOFARO MATOSINHOS - UFVJM



Prof.Dr. CARLOS ALBERTO ARAÚJO JUNIOR - UFMG



Prof.Dr. ALESSANDRO VIVAS ANDRADE - UFVJM

AGRADECIMENTOS

A Deus, por todas as oportunidades;

Aos meus pais Livia e Luciano, pelo apoio constante e incondicional;

À minha esposa Andreza, pelo carinho, estímulo, pela amizade e compreensão nas dificuldades e nos bons momentos durante o curso;

À Universidade Federal dos Vales do Jequitinhonha e Mucuri e ao Departamento de Engenharia Florestal, pela oportunidade de realização do Curso;

Aos Professores Eric Bastos Görgens e Gilciano Saraiva Nogueira, pela orientação, dedicação, amizade e confiança;

Ao Professor Euler Guimarães Horta, pela ajuda, dedicação, confiança e amizade;

À equipe do projeto Paisagens Sustentáveis Brasil¹, em especial à Maiza Nara dos Santos, por gentilmente terem cedido os dados para realização da pesquisa;

À equipe do grupo de pesquisa Otimização e Inteligência Artificial - OIA - DECOM/UFVJM, em especial ao Professor Alessandro Vivas Andrade, pela ajuda, dedicação, confiança e amizade;

Aos grandes amigos Humberto Antônio dos Santos e Sérgio Veloso Silva, pelo apoio constante;

Ao coordenador da pós-graduação, Professor Marcio Leles R. de Oliveira;

Aos funcionários da secretaria do DEF, Madalena e Gilmar;

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

¹ <<https://www.paisagenslidar.cnptia.embrapa.br/webgis/>>

*“Cedo ou tarde você vai perceber, como eu, que
há uma diferença entre conhecer o caminho e
percorrer o caminho.”
(Matrix)*

RESUMO

A metodologia atual de determinação do potencial produtivo madeireiro no âmbito dos planos de manejo florestal, resultam frequentemente em intervenções desnecessárias, em dimensionamento equivocado de pátios, na estimativa errônea do estoque e de unidades de produção. Isto ocorre, em muitos casos, em decorrência da falta de informação prévia para definição inicial das unidades de trabalho, o que dificulta a otimização do dimensionamento em função da regulação florestal. Com os avanços no sensoriamento remoto, principalmente pelo crescimento da utilização da tecnologia de escaneamento por laser aerotransportado no setor florestal, surge a proposta de mapear o potencial madeireiro de áreas de floresta amazônica, possibilitando a determinação espacialmente explícita do potencial produtivo de áreas específicas bem como das árvores de interesse de manejo florestal. Para atingir os objetivos deste trabalho foi proposto um índice de incerteza para avaliar a correspondência entre características dos dados florestais provenientes do inventário florestal e das nuvens de pontos 3d obtidas do escaneamento por laser aerotransportado. Os dados com baixo nível de incerteza foram utilizados na modelagem estatística dos diâmetros, e na validação dos resultados no quesito localização de árvores. Foram localizadas 32% das árvores com diâmetro superior à 50 *cm* em relação aos dados de inventário florestal. Pode-se alcançar níveis de localização na ordem de 60% caso sejam utilizadas folgas no método. As análises qualitativas da estrutura da floresta composta pela amostragem de árvores localizadas no processo, constaram que a estrutura localizada é equivalente à amostrada no inventário florestal. O mapeamento do potencial produtivo realizado neste estudo pode prover informações relevantes para o dimensionamento das unidades de produção anual, podendo favorecer o planejamento de unidades de produção anual com enfoque na regulação florestal. Deste modo, foi possível obter informações importantes para o manejo florestal de precisão e uso sustentável dos recursos florestais.

Palavras-chave: *LiDAR*. Visão computacional. Manejo florestal de precisão.

ABSTRACT

The current methodology for determining the productive potential of timber in the context of forest management plans often results in unnecessary interventions, erroneous design of yards, erroneous estimation of stock and production units. This occurs, in many cases, due to the lack of previous information for the initial definition of the work units, which makes it difficult to optimize the sizing due to forest regulation. With advances in remote sensing, mainly due to the increased use of airborne laser scanning technology in the forestry sector, the proposal for mapping the potential of woodland areas of the Amazon forest, making possible the spatially explicit determination of the productive potential of specific areas as well as trees of forest management interest. The objectives of this work were to propose an uncertainty index to evaluate the correspondence between characteristics of forest data from forest inventory and clouds of points 3d. The data with low level of uncertainty were used in the statistical modeling of the diameters, and in the validation of the results in the location of trees. 32% of the trees with a diameter greater than 50 *cm* were found in relation to the forest inventory data. Localization levels of the order of 60% can be achieved if gaps are used in the method. The qualitative analyzes of the forest structure composed by the sampling of trees located in the process, showed that the localized structure is equivalent to that sampled in the forest inventory. The mapping of the productive potential can provide information relevant to the design of the annual production units and, and may favor the planning of annual production units with a focus on forest regulation. In this way, it was possible to obtain important information for the forest management of precision and sustainable use of forest resources.

Keywords: *LiDAR*. Computer vision. Precision forest management.

LISTA DE ILUSTRAÇÕES

Figura 1 – Disposição espacial das parcelas do inventário florestal em relação ao modelo digital de superfície obtido por meio do sobrevoô por laser aerotransportado da área de estudo.	36
Figura 2 – Fluxograma da metodologia proposta para este trabalho.	37
Figura 3 – Modelo digital de superfície referente a um corte em região de 80 m^2 e <i>keypoints</i> extraídos.	38
Figura 4 – Exemplo de aplicação do algoritmo de extração de raio de copa de nuvem de pontos 3d. (a) Representação gráfica das iterações do algoritmo com o critério de parada representado pelo asterisco azul. (b) Copa extraída nas direções norte, sul, leste e oeste.	41
Figura 5 – Divisão em quadrantes para estimativa do chão por meio da análise de janelas de 25 m^2 de nuvens de pontos 3d.	42
Figura 6 – Representação da classe árvore obtida após processamento de dados por meio da correspondência por características.	46
Figura 7 – Resultados da aplicação do método de correspondência de características proposto (a) e aplicação da detecção de máximos locais e copa pelo método de (POPESCU; WYNNE, 2004; TIEDE; HOCHLEITNER; BLASCHKE, 2005) (b) para uma mesma região.	47
Figura 8 – Erro quadrático médio em relação ao nível de incerteza aferido pelo índice de incerteza entre as características altura e raio de copa médio.	47
Figura 9 – Número de árvores na base de dados em relação ao valor do índice de incerteza <i>idx</i>	48
Figura 10 – Resultados das variações no <i>idx</i> em relação a modelagem estatística do diâmetro em função das alturas <i>LiDAR</i> e medidas no inventário florestal.	49
Figura 11 – Resultados das variações no <i>idx</i> em relação a modelagem estatística do diâmetro em função do raio de copa médio extraído do <i>LiDAR</i> e medido no inventário florestal.	50
Figura 12 – Gráfico de dispersão entre a altura das árvores x DBH.	50
Figura 13 – Dispersão de resíduos entre a altura obtida pelo modelo <i>LiDAR</i> e a variável altura do inventário florestal para todos dados e após cortes no <i>Idx</i>	51
Figura 14 – Gráfico de dispersão entre o raio de copa médio x DBH.	51
Figura 15 – Dispersão de resíduos entre os raios médios de copa obtidos por meio do <i>LiDAR</i> e inventário florestal em relação ao diâmetro medido em campo para diferentes cortes no <i>Idx</i>	52
Figura 16 – Boxplot da composição percentual do <i>idx</i> dada cada uma das características estudadas.	53

Figura 17 – Fluxograma da metodologia utilizada neste trabalho.	64
Figura 18 – Representação da característica definida como índice de competitividade. Árvore que recebe luz direta (a). Árvore com vizinhas mais altas (b).	67
Figura 19 – Definição dos percentuais de aproveitamento da madeira para planejamento de UPAs.	71
Figura 20 – Intensidades de <i>keypoints</i> amostrados por diferentes funções de janelas de busca aplicadas ao algoritmo de máximos locais.	73
Figura 21 – Dispersão das alturas extraídas dos dados <i>LiDAR</i> e diâmetros medidos em campo, dadas as tranformações de dados descritas nos modelos: - parabólico (A), - reta (B), - Stofel (C) e Curtis (D).	74
Figura 22 – Distribuição dos resíduos em percentagem do diâmetro em função da altura <i>LiDAR</i> para os modelos: - parabólico (A), - reta (B), - Stofel (C) e Curtis (D).	75
Figura 23 – Comparação entre os resíduos porcentuais em relação ao DBH em função das alturas extraídas do <i>LiDAR</i> e medidas no inventário.	76
Figura 24 – Filtro (idx).	77
Figura 25 – Mapas da localização remota de árvores em relação ao inventário florestal, para árvores com diâmetro superiores à 50 <i>cm</i> , em uma parcela com baixo nível percentual de árvores localizadas (Parcela 18) e outra parcela com bom nível percentual de árvores localizadas (Parcela 8).	79
Figura 26 – Mapas da localização remota de árvores em relação ao inventário florestal, para árvores com diâmetro superiores à 45 <i>cm</i> , em uma parcela com baixo nível percentual de árvores localizadas (Parcela 18) e outra parcela com bom nível percentual de árvores localizadas (Parcela 8).	80
Figura 27 – Resíduos porcentuais da altura ajstada em relação à altura extraída do <i>LiDAR</i>	83
Figura 28 – Mapa do dimensionamento de 5 unidades de produção anual - Exemplo prático.	85

LISTA DE TABELAS

Tabela 1 – Análise descritiva dos dados do inventário florestal.	35
Tabela 2 – Parâmetros da aquisição da nuvem de pontos.	35
Tabela 3 – Efeito <i>d de Cohen</i> para as características altura e raio de copa médio, dadas as variações nos cortes do $idx \leq 5$; $idx \leq 1$ e $idx \leq 0.5$	48
Tabela 4 – Análise descritiva dos dados do inventário florestal.	63
Tabela 5 – Lista em ordem decrescente das 15 espécies com maior valor de IVI amostradas no inventário florestal para indivíduos com diâmetro igual ou superior à 50 cm.	63
Tabela 6 – Parâmetros da aquisição da nuvem de pontos.	64
Tabela 7 – Parâmetros pré-definidos para as diferentes funções de janela de busca avaliadas.	65
Tabela 8 – Matriz confusão.	68
Tabela 9 – Sistema de equações genérica para estimativa de volume de árvores com os respectivos coeficientes de regressão e coeficiente de ajuste por estratos diamétricos.	71
Tabela 10 – Resultados referentes à avaliação de performance do classificador SVM - filtro de acordo com o experimento proposto.	74
Tabela 11 – Equações diamétricas ajustadas em função da altura e estatísticas do ajuste para os modelos: - parabólico (A), - reta (B), - Stofel (C) e Curtis (D).	75
Tabela 12 – Resultados da localização remota de árvores em relação aos dados do inventário florestal.	78
Tabela 13 – Lista em ordem decrescente das 15 espécies com maior valor de IVI localizadas pelo <i>LiDAR</i>	81
Tabela 14 – Não encontradas	81
Tabela 15 – Não encontradas dentre as primeiras 15	82
Tabela 16 – Taxas utilizadas no planejamento do dimensionamento de UPAs.	83
Tabela 17 – Análise para definição do número de UPAs.	84
Tabela 18 – Informações detalhadas das 5 unidades de produção anual - Exemplo prático.	86

LISTA DE ABREVIATURAS E SIGLAS

ALS	<i>Airborne Laser Scanning</i>
AMF	Área de Manejo Florestal
<i>arv</i>	Referência a dados de árvore do inventário florestal
<i>C</i>	Parâmetro custo do classificador SVM
Car	Características altura ou raio de copa médio
CarLiDAR	Característica altura ou raio de copa médio extraída dos dados <i>LiDAR</i>
CarINV	Característica altura ou raio de copa médio medida no inventário florestal
<i>Chao_{ptmedio}</i>	Estimativa da elevação do chão no ponto central dada janela de $25m^2$
<i>DA</i>	Densidade absoluta
DBH	Diâmetro da árvore medido à $1,3m$ do chão
<i>Dist</i>	Distância entre pontos
<i>DoA</i>	Dominância absoluta
<i>DoR</i>	Dominância relativa
<i>DR</i>	Densidade relativa
<i>erromax_{GPS}</i>	Erro máximo de correção
<i>Est</i>	Dado estimado
<i>FA</i>	Frequência absoluta
FN	Falso negativo
FP	Falso positivo
<i>FR</i>	Frequência relativa
GPS	<i>Global Positioning System</i>
<i>Ht</i>	Altura da árvore medida no inventário florestal
\overline{Ht}	Média da altura das árvores do inventário florestal
<i>HtLiDAR</i>	Altura da árvore extraída dos dados <i>LiDAR</i>
<i>idx</i>	Índice de incerteza para correspondência entre características
<i>Inv</i>	Referência aos dados do inventário florestal

IVC	Índice do valor de cobertura
IVI	Índice de valor de importância
k	Parâmetro do algoritmo <i>k-means</i> que define o número de grupos
kp	Referência a dados de <i>keypoint</i> extraídos dos dados <i>LiDAR</i>
<i>Las</i>	Referência aos dados <i>LiDAR</i>
<i>LiDAR</i>	<i>Light Detection and Ranging</i>
LMF	<i>Local Maxima Filter</i>
MDA	Modelo Digital de Altura
MDS	Modelo Digital de Superfície
MDT	Modelo Digital de Terreno
MSE	Erro quadrático médio
<i>Obs</i>	Amostra de dado observado em campo ou extraído dos dados <i>LiDAR</i>
PMFS	Plano de Manejo Florestal Sustentável
<i>Quad</i>	Quadrante
R^2	Coefficiente de determinação
<i>RaioCopa</i>	Raio de copa
<i>RCM</i>	Raio de copa médio medido no inventário florestal
\overline{RCM}	Média do raio de copa médio das árvores do inventário florestal
<i>RCMLiDAR</i>	Raio de copa médio extraído dos dados <i>LiDAR</i>
RMSE	Raiz do erro quadrático médio
SVM	<i>Support Vector Machine</i>
UML	<i>Unified Modeling Language</i>
UPA	Unidade de Produção Anual
UT	Unidades de Trabalho
UTM	Sistema de coordenadas
Var_z	Variação de elevação entre <i>pixels</i>

VN	Verdadeiro negativo
Vol	Volume da árvore
VP	Verdadeiro positivo
X	Posição UTM da coordenada leste
Y	Posição UTM da coordenada norte
Z	Aferição da elevação de um ponto em relação à superfície
γ	Parâmetro de configuração do classificador SVM
σ_{Ht}	Desvio padrão da altura das árvores do inventário florestal
σ_{RCM}	Desvio padrão do raio de copa médio das árvores do inventário florestal

SUMÁRIO

INTRODUÇÃO GERAL	21
1 OBJETIVO	24
2 OBJETIVOS ESPECÍFICOS	24
3 ORGANIZAÇÃO DA TESE	25
CAPÍTULO 1 - CORRESPONDÊNCIA DE CARACTERÍSTICAS ENTRE DADOS DO INVENTÁRIO FLORESTAL E <i>LiDAR</i> EM ÁREA DE FLORESTA AMAZÔNICA	29
1 INTRODUÇÃO	33
2 OBJETIVO	34
3 MATERIAL E MÉTODOS	34
3.1 Extração de características da nuvem de pontos 3d - <i>LiDAR</i>	40
3.2 Avaliação do resultados	43
4 RESULTADOS E DISCUSSÃO	45
5 CONCLUSÕES	53
CAPÍTULO 2 - MAPEAMENTO DO POTENCIAL MADEIREIRO NUMA ÁREA DE FLORESTA AMAZÔNICA POR MEIO DO ESCANEAMENTO POR LASER AEROTRANSPORTADO	57
1 INTRODUÇÃO	61
2 OBJETIVO	62
3 MATERIAL E MÉTODOS	62
3.1 Extração de <i>keypoints</i>	65
3.2 Extração de características	66
3.3 Classificação - Filtro	67
3.4 Modelagem estatística	68
3.5 Validação da localização das árvores	69
3.6 Dimensionamento das Unidades de Produção Anual	70
4 RESULTADOS E DISCUSSÃO	72
4.1 Modelagem estatística	73
4.2 Validação da localização de árvores	77
4.3 Dimensionamento das Unidades de Produção Anual	82
5 CONCLUSÕES	86
CONSIDERAÇÕES FINAIS	87

REFERÊNCIAS 88

INTRODUÇÃO GERAL

A Floresta Amazônica é reconhecida como a maior reserva tropical da terra. No Brasil, ela ocupa uma área de 4,2 milhões de quilômetros quadrados perfazendo aproximadamente 49,3% do território brasileiro e 23,5% do continente sul-americano (SNIF, 2019). Em termos de biodiversidade, a Amazônia possui 30% das florestas tropicais do planeta e contempla cerca de 30% de toda a biodiversidade. A Floresta Amazônica apresenta em média cerca de 350 toneladas de biomassa por hectare (REIS; RIBEIRO, 2014).

Na Amazônia, deve-se atentar para o problema do controle do desmatamento indiscriminado da floresta nativa da região. De acordo com o INPE (2019), entre os anos 2014 e 2018, em média foram desmatados $7000 \text{ km}^2/\text{ano}$ da Floresta Amazônica.

Para que a Floresta Amazônica prospere, é imprescindível que haja o equilíbrio entre a exploração e a preservação dos recursos florestais. Dentro deste contexto, deve-se lançar mão do manejo florestal sustentável, que consiste na administração da floresta visando o uso consciente dos recursos econômicos, sociais e ambientais, atentando para os mecanismos de sustentação do ecossistema a ser manejado (SNIF, 2019).

Nas últimas décadas, temos vivenciado grandes avanços nas áreas de tecnologias da informação. Tanto do ponto de vista do *hardware*, por meio do desenvolvimento de instrumentos cada vez mais modernos, com menor requisitos de bateria, menor dissipação de calor, mais leves e cada vez menores. Quanto do ponto de vista do *software*, com destaque para evolução das áreas de mineração de dados, inteligência computacional, e *bigdata*. Pode-se perceber no cenário atual, uma forte tendência na maximização da utilização da informação, independente do formato no qual ela esteja configurada ou armazenada, principalmente no intuito favorecer às tomadas de decisão.

Avaliando-se esse contexto de evoluções, inicialmente com o enfoque nos avanços no sensoriamento remoto, Figueiredo, Braz e d'Oliveira (2007) relatam o surgimento, na área florestal, do conceito de manejo florestal de precisão. De acordo com Ferreira (2012) o manejo florestal de precisão tem enfoque na melhoria de processos destinados à sustentabilidade dos recursos florestais, dada principalmente pela aplicação de novas tecnologias.

Os avanços na área de geoprocessamento principalmente pela possibilidade de incorporação dos receptores GPS ao manejo florestal de precisão, propiciaram o inventário por coordenadas cartesianas, ou inventário X-Y (REIS et al., 2013). Neste tipo de inventário, além de serem coletadas as informações do inventário tradicional, como diâmetro, altura, dentre outras, são também coletados dados de posicionamento por coordenadas cartesianas.

Os inventários X-Y vêm favorecendo o planejamento da exploração florestal, mas ainda sim, os inventários em florestas tropicais têm características de censo, o que os tornam custosos no quesito de aplicação de recursos financeiros e humanos Figueiredo, Braz e d'Oliveira (2007).

Outro sensor que vem se tornando atrativo para utilização no setor florestal é o *LiDAR* (*Light Detection and Ranging*), principalmente pelas facilidades de mapeamento de características de árvores e dos povoamentos florestais nativos ou plantados (POPESCU; WYNNE;

NELSON, 2002; TIEDE; HOCHLEITNER; BLASCHKE, 2005), dadas pela cobertura de áreas extensas por poder ser acoplado à aviões ou drones (ZONETE, 2009).

A tecnologia de escaneamento por laser aerotransportado (do inglês *Airborne Laser Scanning* - ALS) tem como premissa os mesmos princípios utilizados no sistema de RADAR, mas, ao invés de se usar ondas de rádio, o sistema *LiDAR* utiliza pulsos laser para localizar objetos de interesse (GIONGO et al., 2010).

O sistema ALS conta com um dispositivo que emite e recebe pulsos laser (*LiDAR*), possui GPS embarcado, responsável por coletar as características de espacialidade dos dados. O ALS possui sistema de estabilização e pêndulo, utilizados para realizar e otimizar varreduras em maiores áreas (JENSEN, 2007 apud GEOG. . . , 2017). Além disso, esse sistema conta com processador e unidade para armazenamento de dados.

A informação mais básica que o sistema ALS permite coletar é a posição XYZ de cada retorno, referente à emissão de um pulso laser que atinge a superfície e retorna após sua reflexão. A posição XY de cada retorno é dada pelas coordenadas UTM. A variável Z armazena a elevação do retorno em relação ao ponto de referência estabelecido para a pesquisa (GÖRGENS, 2014).

Vários estudos vêm apontando positivamente para as potencialidades do uso da tecnologia *LiDAR* para estimar parâmetros de áreas florestais, no intuito de favorecer o planejamento e manejo florestal, como por exemplo na quantificação do estoque florestal e biomassa. Principalmente pela precisão que as variáveis florestais são estimadas pelo sensor *LiDAR* (NÆSSET, 2002; PIRES, 2005; HUDAK et al., 2008; MACEDO, 2009; ZONETE, 2009; RIBAS, 2011; HYYPPÄ et al., 2012; YAO; KRZYTEK; HEURICH, 2012; VALBUENA et al., 2013; GÖRGENS, 2014).

Um fator importante e característico do *LiDAR*, se dá pela aferição precisa da altura das árvores (POPESCU; WYNNE, 2004; PIRES, 2005). Essa característica normalmente apresenta dificuldades na sua aquisição em campo, tanto pela logística quanto na precisão aferida. Esse fato se agrava, em áreas de florestas nativas densas, pois em muitos casos nem mesmo se tem a visão direta dos picos das árvores.

Outra característica que pode ser extraída dos dados *LiDAR* é o diâmetro de copa (MALTAMO et al., 2004; TIEDE; HOCHLEITNER; BLASCHKE, 2005). Conforme Nutto (2001), o diâmetro de copa apresenta alta correlação com o volume e biomassa de árvores. Tais informações podem ser consideradas altamente relevantes para o manejo florestal de precisão.

Entretanto, as aplicações do *LiDAR* aerotransportado permitem uma visão superior do dossel da floresta, desta forma, o *LiDAR* não realiza a detecção direta do diâmetro das árvores. Maltamo et al. (2004), Zandoná, Lingnau e Nakajima (2008), Oliveira et al. (2014) têm estudado modelos diamétricos em função das alturas das árvores extraídas dos dados *LiDAR*, para se obter de forma indireta o diâmetro das árvores. Porém, esses estudos tem enfoque em ambientes controlados, ou em áreas que remetem a espécies que apresentam copas bem definidas e baixa densidade de árvores. Tiede, Hochleitner e Blaschke (2005), Zandoná, Lingnau e Nakajima (2007) relatam que em florestas naturais, a densidade de árvores pode afetar negativamente os

resultados obtidos por esses métodos, tendo em vista a dificuldade de extração das informações das copas dos dados *LiDAR* nestes cenários.

No Brasil, em geral, a exploração legal dos recursos florestais só pode ser realizada sob regime sustentável, por meio do desenvolvimento e aprovação do Plano de Manejo Florestal Sustentável - PMFS. Em 2009, foram estabelecidos critérios técnicos a serem adotados nos PMFS (Conselho Nacional do Meio Ambiente - CONAMA, 2009). Dentre os critérios definidos nesta resolução define-se que a exploração madeireira só pode ocorrer para árvores com diâmetro superiores a 50 *cm*.

Diante do problema de identificação do diâmetro das árvores de florestas densas por meio dos dados *LiDAR*, pode-se pensar em estratégias que correlacione os dados do inventário florestal e os dados de nuvens de pontos 3d, no intuito de realizar a modelagem estatística do diâmetro. Desta forma, o primeiro problema que surge é dado pela localização espacial das árvores em relação ao inventário, para que haja a correlação.

Na prática, o processo mais usual para localização de árvores individuais de acordo com Ke e Quackenbush (2011), é dado pela localização dos máximos locais ao se utilizar o algoritmo LMF (Local Maxima Filter) proposto por Popescu e Wynne (2004). Em seguida, é aplicada uma técnica de detecção de copa de acordo com os pontos de máximo locais encontrados pelo algoritmo LMF. Um método que teve boa aceitação na detecção de copas foi proposto por Tiede, Hochleitner e Blaschke (2005).

Uma vez que foram extraídos dos dados *LiDAR* os pontos de máximo das árvores e as copas, pode-se correlacionar essas informações com as coordenadas amostradas em campo advindas do inventário X-Y. Neste ponto deve-se proceder a avaliação dos resultados em função da eficiência na localização das árvores.

A avaliação dos resultados que envolvem a localização das árvores por meio do *LiDAR* é dada pelos erros de omissão e comissão (WULDER; NIEMANN; GOODENOUGH, 2000; TIEDE; HOCHLEITNER; BLASCHKE, 2005). O erro de omissão é definido pela ocorrência de uma árvore mapeada no inventário X-Y não estar coberta na demarcação de uma copa extraída dos dados *LiDAR*, mas ela ocorre ali de fato. O erro de comissão é dado pela ocorrência de uma árvore definida dentre os limites de uma copa, porém essa árvore não existe verdadeiramente naquela posição.

De fato, as análises dos erros de comissão e omissão podem ser úteis como critério para avaliar a localização de árvores. Porém, quando se pretende correlacionar os dados de inventário aos dados *LiDAR*, esses erros não fornecem informações suficientes para que essa correlação seja efetuada. Ou seja, acabam por gerar cenários de incerteza que podem afetar os processos de tomada de decisão (LEMES et al., 2011). Os problemas relacionados à incerteza nesse tipo de aplicação são agravados principalmente por variações de precisão, provenientes dos diferentes tipos de sistemas GPS utilizados no processo.

Valbuena et al. (2013) estudaram as diferenças nas aferições de localizações de árvores dadas entre os dados das coordenadas do inventário X-Y (aferidas com aparelho GPS de campo) e os dados advindos dos sensores GPS embutidos nos sistemas ALS, e foi percebido que

existe um erro denominado de corregristo. O erro de corregristo é dado pela independência nas aferições de coordenadas pelo uso de diferentes tecnologias GPS. Portanto, este erro deve ser avaliado para fins de correlacionar os dados *LiDAR* e os dados de inventário florestal.

Ussyshkin, Smith e Fidera (2006) avaliaram a precisão geral da posição dos pontos obtidos pelo sistema ALTM 3100, sistema *LiDAR* utilizado neste trabalho. Foi constatado que a precisão é dependente do desempenho da tecnologia GPS embutida ao sistema, mas o erro de posição após o pré-processamento dos dados *LiDAR* é sempre menor do que 5 *cm*.

Em contrapartida, a precisão média dos receptores GPS de mão, utilizados nos inventários X-Y, pode variar de 5 a 25 *m*, podendo aumentar de acordo com o modelo do aparelho (DIVIS, 2000). De acordo com Watzlawick, Sanquetta e Kirchner (2005) a precisão dos receptores GPS de mão pode ser limitada em locais de vegetação densa, ou até mesmo por outros obstáculos físicos que possam impedir a recepção dos sinais emitidos pelos satélites.

Portanto, como os dispositivos GPS utilizados em campo tendem a apresentar erros relativamente consideráveis, existe a incerteza da localização correta de uma árvore, aferida com tecnologia diferente da que foi utilizada para mapear a nuvem de pontos 3d, que é mais precisa.

Estudos da incerteza associada à correlação dos dados *LiDAR* com as fontes de dados do inventário florestal X-Y podem favorecer o manejo florestal de precisão, por meio de obtenção de informações mais ricas e assertivas na condução de estratégias de uso sustentável dos recursos florestais. Acredita-se que o manejo florestal de precisão caminhe nesse sentido.

Algumas potencialidades ao manejo florestal de precisão que podem ser realizadas ou aprimoradas com essa prática são dadas por:

- Utilização dos dados de inventário como variáveis dependentes em modelos de regressão tendo as características extraídas das nuvens de pontos 3d *LiDAR* como variáveis independentes. Visando assim, potencializar predições de volume ou biomassa com melhores níveis de precisão;
- Possibilitar estudos de correspondência e mapeamento de espécies florestais utilizando as informações complementares dos dados de inventário e nuvens de pontos 3d;
- Mapeamento de unidades de manejo do ponto de vista do potencial madeireiro (associação do diâmetro das árvores medidas no inventário florestal e altura das árvores extraídas dos dados *LiDAR*).

1 OBJETIVO

O objetivo principal deste trabalho foi mapear o potencial produtivo em unidades de manejo florestal a partir de informações obtidas por meio de levantamento por laser aerotransportado, em áreas de floresta amazônica.

2 OBJETIVOS ESPECÍFICOS

- Propor metodologia para realizar correspondência entre características (*feature matching*) do inventário florestal e de nuvens de pontos 3d obtidas do escaneamento por laser aerotransportado, propiciando informações complementares para aplicações em manejo florestal de precisão, numa área de floresta amazônica.
- Propor metodologia para determinação espacialmente explícita do potencial produtivo em áreas de floresta densa bem como das árvores de interesse de manejo florestal.

3 ORGANIZAÇÃO DA TESE

Para atingir os objetivos propostos, o trabalho foi organizado em dois capítulos. No primeiro capítulo, realizou-se a proposição da criação de um índice de incerteza para avaliar a correspondência entre características do inventário florestal, e extraídas dos dados *LiDAR*.

No segundo capítulo foi proposta uma metodologia para localizar árvores de interesse do manejo florestal, em áreas de floresta amazônica por meio da análise de nuvens de pontos 3d, obtidas do *LiDAR*. As árvores localizadas foram utilizadas no dimensionamento de unidades de produção anual.

**CORRESPONDÊNCIA DE CARACTERÍSTICAS ENTRE DADOS DO INVENTÁRIO FLORESTAL E
LiDAR EM ÁREA DE FLORESTA AMAZÔNICA**

1 CORRESPONDÊNCIA DE CARACTERÍSTICAS ENTRE DADOS DO INVENTÁRIO FLORESTAL E *LiDAR* EM ÁREA DE FLORESTA AMAZÔNICA

RESUMO

Correlacionar informações de inventário florestal e escaneamento por laser aerotransportado pode favorecer o manejo florestal de precisão. Pode-se obter benefícios ao se associar a certeza das medições de campo com a potencialidade de varreduras em áreas extensas, possibilitadas pelo escaneamento por laser aerotransportado. Entretanto, associar fontes de dados florestais, que utilizam tecnologias de sensoriamento remoto diferentes, nem sempre é uma tarefa fácil. Os erros de precisão associados aos diversos tipos de sistemas GPS aplicados ao manejo florestal de precisão (Satélite, *LiDAR*, Campo), tendem a proporcionar baixa adequação entre a localização de objetos de interesse. Técnicas da visão computacional podem ser utilizadas para aferir a incerteza ao se correlacionar dados do inventário florestal e dados provenientes do escaneamento por laser aerotransportado, do ponto de vista de árvores individuais. O objetivo deste trabalho foi propor uma metodologia para realizar a correspondência entre características (*feature matching*) do inventário florestal e de nuvens de pontos 3d obtidas do escaneamento por laser aerotransportado, propiciando informações complementares para aplicações em manejo florestal de precisão, numa área de floresta amazônica. Foi proposto um índice para aferir o nível de incerteza relacionado à correlação entre as características distância de correlograma, altura e raio de copa médio, extraídas das nuvens de pontos 3d e medidas no inventário florestal. Avaliou-se as intensidades de incerteza para cada árvore medida no inventário florestal, em relação a um conjunto de pontos potenciais extraídos da nuvem de pontos 3d. A precisão do casamento de informações foi avaliada por meio da análise de diferentes níveis de incerteza. Constatou-se que o casamento entre as características extraídas das nuvens de pontos 3d em relação aos dados do inventário foi realizada com sucesso. Cortes restritivos no valor do índice de incerteza definem maior precisão no casamento das características, porém, restringem o número de árvores para análise. Novos estudos com o enfoque na inserção de outras características no processo de correspondência entre dados obtidos do escaneamento por laser aerotransportado e dados do inventário florestal, assim como, melhorias nos processos de extração de características das nuvens de pontos 3d podem tornar o método mais preciso.

Palavras-chave: Manejo florestal de precisão. Visão computacional. Índice de incerteza.

1 CORRESPONDENCE OF CHARACTERISTICS BETWEEN FOREST INVENTORY DATA AND LIDAR IN AMAZON FOREST AREA

ABSTRACT

The correlation between forest inventory information and airborne laser scanning may benefit forest management. The benefits can be obtained by the association of the certainty of the field measurements with the possibilities of overflights in large areas, made possible by the airborne laser scanning. However, associating forest data sources, which use different remote sensing technologies, is not an easy task. The precision errors associated with the various types of GPS systems applied to precision forest management (Satellite, *LiDAR*, Field) tend to provide low adequacy between the location of objects of interest. Computational vision techniques can be used to measure uncertainty when correlating forest inventory data and data obtained from airborne laser scanning from the standpoint of individual tree analysis. The aim of this study was to propose a feature matching of inventory and 3d point clouds obtained from airborne laser scanning, providing complementary information for applications in precision forest management, in an area of Amazon rainforest. An index was proposed to measure the level of uncertainty related to the correlation between distance, height and median canopy radius, extracted from the 3d point cloud and measured in the forest inventory. The uncertainty intensity was evaluated for each tree measured in the forest inventory, in relation to a set of potential points extracted from the 3d point cloud. The precision of feature matching was evaluated by analyzing different levels of uncertainty. It was verified that the matching between the features extracted from the 3d point clouds in relation to the inventory data was performed successfully. Restrictive cuts in the value of the uncertainty index define greater precision in the feature matching, however, they restrict the number of trees for analysis. New research focusing on the insertion of other characteristics in the process of feature matching between airborne laser scanning and forest inventory, as well as improvements in the extraction processes of the characteristics of 3d point clouds can make the method more precise.

Keywords: Precision forest management. Computer vision. Uncertainty index.

1 INTRODUÇÃO

O sensoriamento remoto tem se beneficiado da evolução dos sistemas embarcados, por meio do desenvolvimento de instrumentos mais modernos, com menor requisitos de bateria, menor dissipação de calor, mais leves e cada vez menores. Essa evolução tem propiciado o uso dos sistemas embarcados em aviões e até mesmo drones. Estes avanços no sensoriamento remoto têm favorecido amplamente o manejo florestal de precisão (FIGUEIREDO; BRAZ; D'OLIVEIRA, 2007). De acordo com Ferreira (2012) o manejo florestal de precisão tem enfoque na melhoria de processos destinados à sustentabilidade dos recursos florestais, dada principalmente pela aplicação de novas tecnologias.

Vários estudos vêm apontando positivamente para as potencialidades do uso da tecnologia *LiDAR* para mapear florestas, dada a precisão das estimativas das variáveis florestais (NÆSSET, 2002; HUDAK et al., 2008; HYYPPÄ et al., 2012; VALBUENA et al., 2013). De acordo com Næsset (2004) essa técnica é utilizada operacionalmente em inventários em nível de talhão. Pode-se dizer que a tecnologia *LiDAR*, aplicada em nível de povoamento, tem se apresentado como alternativa atrativa em relação a processos de campo que demandam alto custo, como por exemplo às atividades de inventário florestal (ZONETE, 2009).

Görgens (2014) relata que as aplicações em nível de povoamento são mais utilizadas na prática. Aplicações do *LiDAR* têm enfoque generalista na quantificação da vegetação, muitas vezes para reduzir os custos ou recursos despendidos no inventário florestal tradicional. Na prática, as aplicações em nível de árvore individual ainda não são utilizadas com frequência. O fato para que isso ocorra se dá pela baixa disponibilidade de dados de campo em nível de árvore individual associados à dados *LiDAR* de alta precisão, com alta densidade de pulsos (GÖRGENS, 2014).

Correlacionar dados de inventário e dados *LiDAR*, principalmente no contexto de árvore individual, pode trazer benefícios ao manejo florestal de precisão. Algumas potencialidades que podem ser realizadas ou aprimoradas são dadas por: - Utilização dos dados de inventário na validação de modelos de regressão usando características extraídas das nuvens de pontos 3d *LiDAR*, podendo vir a potencializar predições de volume ou biomassa com melhores níveis de precisão comparadas às técnicas baseadas em povoamento; - Possibilitar estudos de correspondência e mapeamento de espécies utilizando as informações complementares dos dados de inventário e nuvens de pontos 3d; - Mapeamento de unidades de manejo do ponto de vista do potencial madeireiro (associação do diâmetro das árvores medidas no inventário florestal e altura das árvores extraídas dos dados *LiDAR*).

Uma forma já utilizada para se correlacionar dados do inventário florestal e dados *LiDAR* pode ser descrita por dois processos. O primeiro processo se dá pela aplicação do método proposto por Popescu, Wynne e Nelson (2002), que visa encontrar os máximos locais dada a definição de janelas de busca. Neste caso, define-se que os retornos mais curtos correspondem aos pontos mais altos das árvores, dentre cada janela. Deste modo, a definição da função de

janela de busca afeta diretamente o número de árvores encontradas. No segundo processo, é realizada a obtenção do modelo de copas das árvores (TIEDE; HOCHLEITNER; BLASCHKE, 2005), que à partir dos pontos de máximos locais obtidos anteriormente, define-se quais são os limites entre copas por meio de um algoritmo de busca. Após este processamento define-se que as árvores do inventário, com coordenadas aferidas dentre as copas extraídas no segundo processo, remetem ao ponto de máximo local localizado na mesma região delimitada pela copa extraída.

A avaliação do processo se dá por meio da análise dos erros de omissão, quando uma copa definida não abrange a posição georreferenciada de uma árvore, e ou comissão, quando são definidas duas ou mais copas, geralmente pequenas, numa região em que há apenas uma árvore (WULDER; NIEMANN; GOODENOUGH, 2000; KE; QUACKENBUSH, 2011). Entretanto, esse tipo de análise não leva em consideração o problema associado à incerteza de uma árvore mapeada no processamento dos dados *LiDAR* corresponder realmente à árvore mapeada em campo.

Ferramentas computacionais podem ser utilizadas para se aferir a incerteza ao se correlacionar dados do inventário florestal e dados *LiDAR*, com o enfoque em processos do ponto de vista de árvores individuais. O conhecimento de medida de incerteza pode trazer precisão a análises de correlação entre características *LiDAR* e inventário, tendo em vista que podem ser definidos níveis aceitos de incerteza.

A visão computacional busca o reconhecimento ou identificação de objetos em imagens por meio de modelos abstraídos pela reconstrução de propriedades destes objetos como: forma, iluminação e distribuição de cores (FORSYTH; PONCE, 2003; SZELISKI, 2011). Pode ser feita uma analogia, do ponto de vista de identificar árvores individuais dentre nuvens de pontos *LiDAR* por meio da extração e análise de características conhecidas, como por exemplo a altura ou raio de copa das árvores.

Associar fontes de dados florestais diferentes nem sempre é uma tarefa fácil. Problemas de corregristo entre diferentes tecnologias de dispositivos GPS são comuns. Tecnologias diferentes tendem a proporcionar baixa adequação entre a localização de objetos (Satélite, *LiDAR*, Campo), basicamente por meio de problemas relacionados aos erros entre a precisão dos diferentes tipos de sistemas GPS utilizados.

2 OBJETIVO

O objetivo deste trabalho foi propor uma metodologia para realizar a correspondência entre características (*feature matching*) do inventário florestal e de nuvens de pontos 3d obtidas do escaneamento por laser aerotransportado, propiciando informações complementares para aplicações em manejo florestal de precisão, numa área de floresta amazônica.

3 MATERIAL E MÉTODOS

A área de estudo está localizada na fazenda Cauaxi, município de Paragominas, Estado do Pará e faz parte da Área de Manejo Florestal (AMF) Rio Capim propriedade da empresa CIKEL Brasil Verde Madeira Ltda. A vegetação natural típica é classificada como floresta ombrófila densa. A topografia varia de plana a suave-ondulada, com altitude de 119 metros, tendo como solo predominante o latossolo amarelo distrófico (KEEFE et al., 2009; PINAGÉ et al., 2015; GÖRGENS et al., 2016).

No ano de 2012 foram coletados dados *LiDAR* de alta precisão pela Serviço Florestal dos Estados Unidos, em colaboração com a Empresa Brasileira de Pesquisa Agrícola (EMBRAPA). Foi realizado o inventário florestal no mesmo ano.

Foram avaliadas 22 parcelas com área de 20x500 m, com sobreposição de sub-parcelas com área de 2x500 m, seguindo uma amostragem sistemática, com início aleatório. Árvores com diâmetro à altura do peito (*DBH*) igual ou superiores à 35 cm foram medidas dentro da área da parcela. Na sub-parcela foram medidas árvores com *DBH* igual ou superiores à 10 cm e inferiores à 35 cm.

Os raios de copa foram medidos utilizando uma trena aplicada sobre a projeção da copa no solo. Os diâmetros das árvores foram obtidos utilizando-se fita diamétrica, e foram medidos à 1.3 metros do nível do solo ou acima do término da sapopema. As alturas das árvores foram aferidas usando um hipsômetro modelo *Impulse-200LR*, *Laser Technology Inc.*, *Englewood, CO* (HUNTER et al., 2013). A análise descritiva dos dados obtidos no inventário florestal está apresentada na Tabela 1.

Tabela 1 – Análise descritiva dos dados do inventário florestal.

	Variável	n	Min	Max	Média	Desvio Padrão
<i>DBH</i> < 35 cm	<i>DBH</i>	1124	10.00	34.90	17.57	6.39
	<i>Ht</i>	1124	1.31	56.40	17.80	7.02
	<i>RaioCopa</i>	4496	0.00	17.00	2.15	1.31
<i>DBH</i> ≥ 35 cm	<i>DBH</i>	1425	35.00	200.00	50.49	16.24
	<i>Ht</i>	1425	1.85	71.22	31.02	9.30
	<i>RaioCopa</i>	5700	0.00	21.50	4.06	2.21

Fonte: Elaborada pelo autor.

Os sobrevôos para obtenção dos dados *LiDAR* foram realizados em julho de 2012 na fazenda Cauaxi. De acordo com Pinagé et al. (2015) as características de aquisição da nuvem de pontos são apresentadas na Tabela 2.

Na Figura 1 são apresentadas as unidades de produção anual (UPAs) e as parcelas avaliadas no inventário florestal, dispostas em relação ao modelo digital de superfície - MDS (*Canopy surface model*) da área de estudo.


A metodologia deste trabalho (Figura 2) inicia-se pela extração das características altura e raio de copa médio dos dados *LiDAR*. Essas características foram comparadas com

Tabela 2 – Parâmetros da aquisição da nuvem de pontos.

Característica	Dado
Equipamento	Optech ALTM 3100
Data de aquisição	27-29/07/2012
Altitude máxima de voo (em relação ao terreno)	850 m
Campo de visada	11°
Frequência de pulso	100 KHz
Densidade mínima de retornos	4/m ²
Densidade média de retornos	28.3/m ²
Densidade média de primeiros retornos	13.8/m ²

Fonte: Adaptada de Pinagé et al. (2015).

Figura 1 – Disposição espacial das parcelas do inventário florestal em relação ao modelo digital de superfície obtido por meio do sobrevoô por laser aerotransportado da área de estudo.

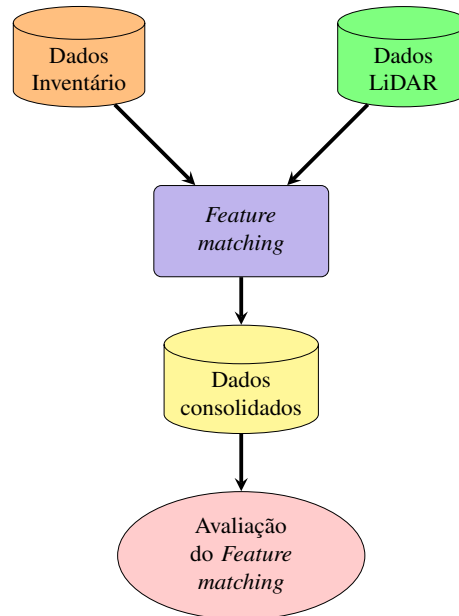


Fonte: Elaborada pelo autor.

os dados do inventário florestal por meio de uma medida de incerteza. Logo após, avaliou-se para cada árvore medida no inventário florestal, as intensidades de incerteza calculadas para um conjunto de pontos potenciais extraídos da nuvem de pontos 3d. Os pontos potenciais que apresentaram baixos níveis de incerteza foram considerados como correspondentes à cada árvore do inventário. A precisão do casamento de informações *LiDAR* e inventário florestal foi avaliada por meio da análise de diferentes níveis de incerteza.

O primeiro processo realizado foi dado pela obtenção do modelo digital de superfície

Figura 2 – Fluxograma da metodologia proposta para este trabalho.



Fonte: Elaborada pelo autor.


- MDS (*Canopy surface model*) da área de estudo, com células configuradas com resolução de 1 x 1 metro. Para isso foi utilizado o *software Fusion* (MCGAUGHEY, 2016) para processar os dados *LiDAR*.

De acordo com Szeliski (2011), as técnicas de correspondência de características (*feature matching*) são dadas pela análise de pontos específicos, chamados de *keypoints*, que remetem à posição aonde as características relevantes podem ser avaliadas e utilizadas na diferenciação de imagens. Os *keypoints*, são dados por posições nas imagens em que as características descritoras são avaliadas. Em muitos casos, eles são usados para facilitar a combinação entre pontos correspondentes em imagens distintas, por meio de análises de precisão.

Foram então realizados cortes no MDS de toda área, planejados para representar a área coberta por cada árvore do inventário. Cada corte foi proposto com o tamanho de 80 x 80 m, tendo como ponto central as coordenadas de cada árvore do inventário. A escolha da dimensão do corte se deu pelo tamanho máximo do raio de copa de 21.5 m encontrado na base de dados do inventário (Tabela 1). Com as dimensões do centro do corte até as bordas medindo 40 metros, foi possível avaliar os raios de copa de árvores que poderiam estar levemente descentralizadas ou próximas das bordas.

Para cada corte de 80 x 80 m foram obtidos os máximos locais utilizando o algoritmo proposto por Popescu e Wynne (2004), com janela definida pela função: $H * 0.01 + 0.6$, em que H representa a altura do *pixel* central no modelo digital de superfície. Foram definidos como *keypoints* os máximos locais de cada região, com a proposição de que cada ponto de máximo tem potencialidade para descrever o topo de uma árvore. Um exemplo de corte em região de 80 x 80 m com os *keypoints* extraídos do MDS é apresentado na Figura 3.

Figura 3 – Modelo digital de superfície referente a um corte em região de 80 m² e *keypoints* extraídos.



Fonte: Elaborada pelo autor.

A definição da função de janela de busca se deu de forma empírica, perfazendo uma elevada intensidade de *keypoints*. Foi utilizada a estratégia de se otimizar a possibilidade de encontrar *keypoints* correspondentes às árvores do inventário.

Foi proposto um índice de incerteza para medir o nível de correspondência entre as características dos dados de árvores do inventário e os *keypoints* extraídos do modelo digital de superfície. Este índice se baseia na relação das distâncias entre as coordenadas das árvores do inventário e coordenadas dos *keypoints*, nas características dos raios de copa extraídos do *LiDAR* em relação aos raios de copa medidos em campo, e nas relações entre as alturas medidas em campo e as alturas extraídas das nuvens de pontos *LiDAR*.

Em relação à característica distância, quanto mais próximos os *keypoints* avaliados estão da árvore em análise, menores são os valores aferidos pelo índice de incerteza. A distância entre a posição da árvore do inventário (medida com GPS de campo) e cada *keypoint* na região avaliada foi obtida pela Equação 1.

$$Dist = \sqrt{(X_{arv} - X_{kp})^2 + (Y_{arv} - Y_{kp})^2} \quad (1)$$

$$erro_{Distância} = \left(\frac{Dist}{erro_{maxGPS}} \right)^2 \quad (2)$$

Em que:

Dist: Distância entre a árvore do inventário e o *keypoint* em análise;

X_{arv} : Posição UTM da coordenada leste em relação à árvore no inventário;

Y_{arv} : Posição UTM da coordenada norte em relação à árvore no inventário;

X_{kp} : Posição UTM da coordenada leste em relação ao *keypoint* sob análise;

Y_{kp} : Posição UTM da coordenada norte em relação ao *keypoint* sob análise.

$erromax_{GPS}$: Erro GPS campo + Erro GPS *LiDAR*.

Diferentes tecnologias utilizadas para receber informações do Sistema de Posicionamento Global (GPS) podem realizar o processamento da posição de um mesmo ponto e retornar resultados de coordenadas diferentes. Esse erro entre tecnologias GPS é conhecido como erro de corregristo. Conforme Ussyshkin, Smith e Fidera (2006), a precisão geral da posição dos pontos obtidos pelo sistema ALTM 3100 é dependente do desempenho da tecnologia GPS embutida ao sistema. Eles constataram que o erro de posição após o pré-processamento dos dados *LiDAR* é sempre menor do que 5 cm. Em contrapartida, a precisão média dos receptores GPS de mão pode variar de 5 a 25 m podendo aumentar de acordo com o modelo do aparelho (DIVIS, 2000). De acordo com Watzlawick, Sanquetta e Kirchner (2005), a precisão do GPS pode ser limitada em locais de vegetação densa ou até mesmo por outros obstáculos físicos que possam impedir a recepção dos sinais emitidos pelos satélites.

O erro associado à distância entre os pontos aferidos pelo GPS de campo e os *keypoints* em análise, provenientes de processamento por meio do GPS embarcado no *LiDAR*, foi calculado levando-se em consideração a variável $erromax_{GPS}$, conforme apresentado na Equação 2. Ou seja, foi proposta a normalização da característica distância considerando-se o erro de corregristo. Neste estudo foi utilizado o $erromax_{GPS} = 10$.

Foram utilizadas a média e o desvio padrão para normalizar as características raio de copa médio e altura das árvores. Desta forma, a amplitude das características foram padronizadas de acordo com a escala e variação, perfazendo média zero e desvio padrão unitário (FACELI et al., 2011).

Para aferir a intensidade de incerteza entre características foi ponderado o erro da altura medida em campo em relação à altura extraída em cada *keypoint* avaliado. O erro da altura foi calculado por meio da Equação 3.

$$erro_{Altura} = \left(\frac{HtLiDAR_{kp} - \overline{Ht}}{\sigma_{Ht}} - \frac{Ht_{arv} - \overline{Ht}}{\sigma_{Ht}} \right)^2 \quad (3)$$

Em que:

Ht_{arv} : Altura de cada árvore (*arv*) medida no inventário florestal;

$HtLiDAR_{kp}$: Altura extraída em cada *keypoint* (*kp*);

\overline{Ht} : Média da altura de todas árvores do inventário florestal;

σ_{Ht} : Desvio padrão da altura de todas árvores do inventário florestal.

Outra característica que compõe o índice de incerteza é dada pelo raio de copa médio. Quanto mais a média dos raios das copas extraídos dos dados *LiDAR* se aproximam da média dos raios das copas medidas em campo, menor é o valor da incerteza. O raio de copa médio (*RCM*) foi obtido pela média aritmética dos raios de copa dadas as direções cardinais (Equação

4). O erro entre raios de copa foi calculado por meio da Equação 5.

$$RCM = \frac{\sum_{DIR=(N,S,L,O)} Raio\ de\ copa_{DIR}}{4} \quad (4)$$

$$erro_{raio\ de\ copa\ médio} = \left(\frac{RCMLiDAR_{kp} - \overline{RCM}}{\sigma_{RCM}} - \frac{RCM_{arv} - \overline{RCM}}{\sigma_{RCM}} \right)^2 \quad (5)$$

Em que:

RCM : Raio de copa médio;

RCM_{arv} : Raio de copa médio de cada árvore (arv) medido no inventário florestal;

$RCMLiDAR_{kp}$: Raio de copa médio extraído em cada *keypoint* (kp);

\overline{RCM} : Média do raio de copa médio de todas árvores do inventário florestal;

σ_{RCM} : Desvio padrão do raio de copa médio de todas árvores do inventário florestal.

O índice de incerteza (idx) proposto neste estudo, é dado por:

$$idx = erro_{Distância} + erro_{Altura} + erro_{raio\ de\ copa\ médio} \quad (6)$$

O índice de incerteza foi calculado para cada *keypoint* localizado dentro de cada região de $80\ m^2$, em relação à árvore do inventário que baliza o corte. Quanto menor é o valor do índice de incerteza, espera-se que haja maior correspondência entre as características dos dados da árvore medida no inventário e a abstração das características da árvore extraídas da nuvem de pontos 3d mapeada pelo *LiDAR*.

O processo finaliza ao se obter o menor valor de incerteza (idx) dentre os *keypoints* avaliados em cada região. Ao se minimizar o idx , pode-se pressupor que ocorreu a correspondência entre as características extraídas da nuvem de pontos 3d *LiDAR* e medidas do inventário florestal. O valor do índice idx remete ao nível de incerteza atingida pela correspondência das características avaliadas, ou seja, quanto menor o valor do índice maior será precisão aferida no casamento entre dados.

As características raio da copa, altura e georreferenciamento de cada árvore foram aferidas diretamente no inventário florestal. Para se calcular o índice de incerteza proposto, foi necessária a extração das mesmas características, altura e raio da copa e posição, indiretamente da nuvem de pontos 3d mapeadas pelo *LiDAR*.

3.1 Extração de características da nuvem de pontos 3d - *LiDAR*

Para a extração dos raios de copa das nuvens de pontos 3d foi utilizada uma adaptação do algoritmo proposto por Curran e Atkinson (1998). Este algoritmo é frequentemente aplicado em problemas do sensoriamento remoto. A adaptação proposta é baseada na avaliação da semivariância da elevação (Z) entre pares de *pixels*. Dadas as direções norte (RN), sul (RS),

leste (RL) e oeste (RO), tomando-se como ponto de partida o ponto central da região em análise, foram avaliadas as variações nas elevações para cada par de *pixel*. Em cada iteração do algoritmo a variação da elevação foi calculada conforme a Equação 7.

$$Var_Z = (Z_i - Z_{(i-1)})^2 \quad (7)$$

Em que:

Var_Z : Variação da elevação entre *pixels*;

Z_i : elevação observada no i – ésimo *pixel*.

Curran e Atkinson (1998) aplicaram critérios empíricos para analisar a semivariância entre pares de *pixels*, ou seja, por meio de valores tabelados foram definidos os tamanho da janelas variáveis, utilizadas por exemplo no algoritmo de LMF (POPESCU; WYNNE, 2004). Para realizar a extração das copas, também foi proposta uma regra de parada empírica para o algoritmo adaptado, com base em variações consideradas como significativas nas elevações, e definidas por meio de avaliação exploratória em comparação com dados do inventário. Enquanto as elevações entre *pixels* perfazem pequenas variações, esses pontos são considerados como pertencentes ao raio de copa da mesma árvore. Quando se observa um salto, conforme Equação 8, o algoritmo de extração do raio de copa eventualmente termina, e então, é definido o raio da copa da árvore em cada direção cardinal.

$$\begin{cases} raio_{copa} = raio_{copa} + 1, & \text{se } Var_Z \leq 1 \\ \text{Define } raio_{copa}, & \text{se } Var_Z > 1 \end{cases} \quad (8)$$

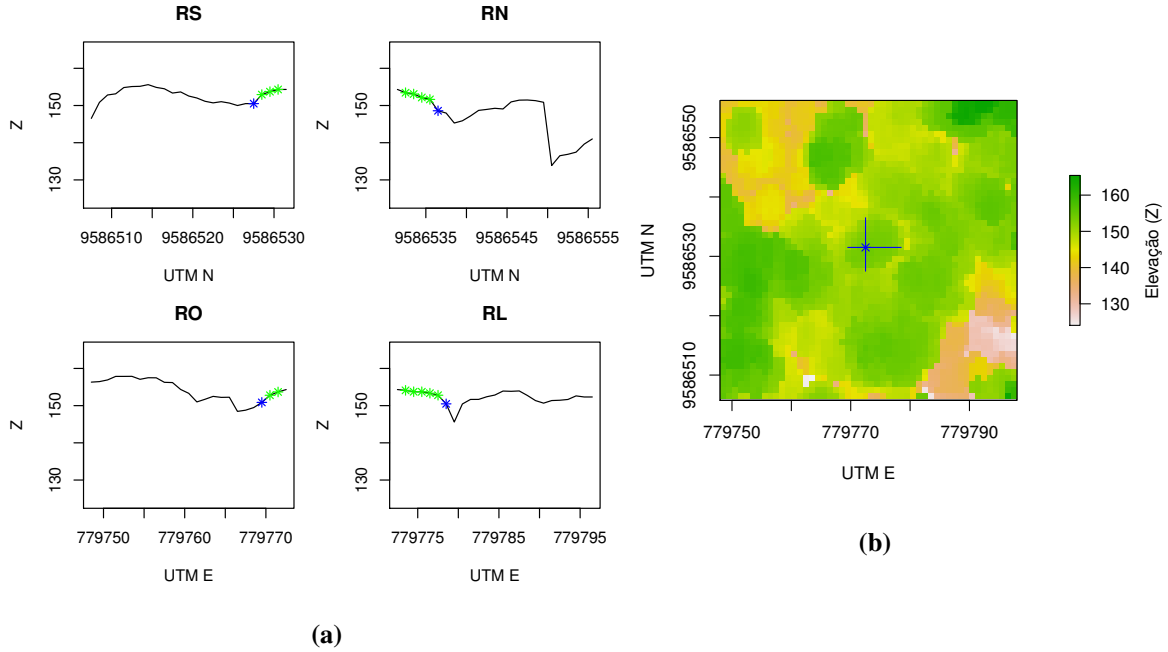
Um exemplo da aplicação do algoritmo de extração de raio de copa adaptado, dada as direções norte (RN), sul (RS), leste (RL) e oeste (RO) é apresentado na Figura 4.

O *LiDAR* permite uma visão superior da floresta, do ponto de vista de cima para baixo. Para se extrair a característica altura das árvores das nuvens de pontos 3d foi preciso identificar o chão. O problema de se extrair informações do posicionamento do chão da nuvem de pontos 3d não é tão simples. A precisão de detecção do chão pode ser influenciada pela declividade do terreno e também pelo tipo de espaçamento e dossel da floresta (HUISING; PEREIRA, 1998). Se a extração do chão não for precisa a qualidade da altura extraída pode ser afetada.

A altura de uma região ou ponto específico geralmente é obtida por meio do Modelo Digital de Altura (*MDA*). Esse modelo é dado pela relação direta entre o Modelo Digital de Superfície e um modelo que estima o solo, chamado de Modelo Digital de Terreno (*MDT*). Em suma o *MDA* é obtido por: $MDA = MDS - MDT$.

Foi proposta uma abstração do chão processando informações diretamente sob a região em análise, sem lançar mão do Modelo Digital de Terreno. A ideia foi centralizar um *keypoint* numa janela de tamanho fixo, neste estudo usou-se janelas de 25 m^2 . Essa janela é

Figura 4 – Exemplo de aplicação do algoritmo de extração de raio de copa de nuvem de pontos 3d. (a) Representação gráfica das iterações do algoritmo com o critério de parada representado pelo asterisco azul. (b) Copa extraída nas direções norte, sul, leste e oeste.



Fonte: Elaborada pelo autor.

então dividida em 4 quadrantes conforme apresentado na Figura 5. Em cada quadrante é obtido o mínimo local, dados pelos retornos mais longos obtidos do *LiDAR*.

A estimativa da altura do chão foi calculada pela média dos pontos de mínimos obtida em cada quadrante (Equação 9). Para se otimizar as estimativas, podem ser lançados mais de um ponto de mínimo por quadrante, visando diminuir o efeito de possíveis declividades ou irregularidades no terreno dentro de cada quadrante.

$$Chao_{ptmedio} = \frac{(Quad_1[Z_{min}] + Quad_2[Z_{min}] + Quad_3[Z_{min}] + Quad_4[Z_{min}])}{4} \quad (9)$$


Em que:

$Chao_{ptmedio}$: Estimativa da elevação do chão no ponto central da janela de $25 m^2$;

$Quad_i[Z_{min}]$: Elevação mínima extraída no i – ésimo quadrante.

A altura extraída de cada *keypoint* foi obtida pela diferença direta entre o valor de Z_{kp} definido no modelo digital de superfície, aferido no ponto central da janela de $25 m^2$, e o $Chao_{ptmedio}$ calculado para cada janela.

Figura 5 – Divisão em quadrantes para estimativa do chão por meio da análise de janelas de 25 m² de nuvens de pontos 3d.



Fonte: Elaborada pelo autor.

3.2 Avaliação do resultados

Para se identificar o valor ideal para o corte no nível de incerteza, foi avaliada a precisão por meio do erro quadrático médio (MSE) (Equação 10), entre as características estudadas. Também foi avaliado o tamanho da base de dados em referência à filtragem nas intensidades de incerteza. Para se realizar as análises, foram propostos cortes no nível de incerteza na ordem de $idx \leq \{5, 1 \text{ e } 0.5\}$.

$$MSE = \frac{\sum_{i=0}^n (CarLiDAR_i - CarINV_i)^2}{n} \quad (10)$$

Em que:

$CarLiDAR_i$ = Observação da característica (altura ou raio de copa médio) para dados extraídos da nuvem de pontos 3d;

$CarINV_i$ = Observação da característica (altura ou raio de copa médio) para dados de inventário;
 $i = i - \acute{e}$ sima representação de árvore do inventário correlacionada à *keypoint* por baixa incerteza;
 n = tamanho da amostra.

Os níveis de correspondência das características entre base dados de inventário e

nuvem de pontos 3d foram avaliados por meio da análise dos gráficos de resíduos entre as distribuições das características estudadas (Equação 11), dados diferentes níveis de incerteza estudados.

$$\text{Erro em \%} = \frac{CarLiDAR_i - CarINV_i}{CarINV_i} \times 100 \quad (11)$$

Em que:

$CarLiDAR_i$ = Observação da característica (altura ou raio de copa médio) para dados extraídos da nuvem de pontos 3d;

$CarINV_i$ = Observação da característica (altura ou raio de copa médio) para dados de inventário;

$i = i - \acute{e}sima$ representação de árvore do inventário correlacionada à *keypoint* por baixa incerteza.

O tamanho do efeito *d de Cohen* (COHEN, 1988.) foi utilizado para aferir o nível de adequação entre os dados. De acordo com Santo e Daniel (2015) o *d de Cohen* pode ser utilizado para expressar a magnitude da diferença entre grupos dada uma determinada característica. A Equação 12 foi utilizada para calcular o *d de Cohen*. Este parâmetro foi utilizado para avaliar o grau de correspondência entre as características altura das árvores e raio de copa médio, extraídas dos dados *LiDAR* e medidos no inventário florestal. As análises foram realizadas levando-se em consideração os valores preestabelecidos dos níveis de incerteza ($idx \leq \{5, 1 \text{ e } 0.5\}$).

$$d \text{ de Cohen} = \frac{|\mu_{LiDAR} - \mu_{Inv}|}{\sigma_{combinado}} \quad (12)$$

$$\sigma_{combinado} = \sqrt{\frac{(n_{LiDAR} - 1)\sigma_{LiDAR}^2 + (n_{Inv} - 1)\sigma_{Inv}^2}{n_{LiDAR} + n_{Inv} - 2}} \quad (13)$$

Em que:

μ = Média de cada grupo;

n = Número de observações de cada grupo;

σ = Desvio padrão de cada grupo;

$\sigma_{combinado}$ = Desvio padrão combinado entre grupos.

Foi proposto um experimento para avaliar a influência da incerteza na modelagem estatística do diâmetro das árvores em função das características (*Car*): altura e raio de copa médio. Para tanto, foram ajustados e comparados os resultados de modelos estatísticos (Equação 14) definidos por: $DBH \approx f(Car_{LiDAR})$ e $DBH \approx f(Car_{inventário})$.

$$DBH = \beta_0 + \beta_1 Car + \beta_2 Car^2 + \varepsilon \quad (14)$$

Em que:

DBH = Diâmetro à altura do peito estimado;

β_i = Parâmetros de ajuste do modelo;

Car = Características altura ou raio de copa médio.

A comparação da precisão entre os modelos foi efetuada por meio de ajustes utilizando-se diferentes amostras de dados, definidas com base em filtragem do diâmetro. Foram realizadas variações no filtro de diâmetro dadas por $DBH \geq 10 \text{ cm}$ até $DBH \geq 70 \text{ cm}$ com alteração de 1 cm para cada teste. Por fim, cada teste foi realizado em repetição, variando-se os valores de incerteza dados por $idx \leq \{10, 5, 4, 3, 2 \text{ e } 1\}$.

Em cada teste foi avaliado o erro quadrático médio (Equação 15) dos diâmetros estimados por meio da altura ou raio de copa médio *LiDAR* e altura ou raio de copa médio do inventário em relação aos diâmetros medidos em campo no inventário florestal.

$$MSE_{DBH} = \frac{\sum_{i=0}^n (DBH_{obs} - DBH_{est})^2}{n} \quad (15)$$

Em que:

DBH_{obs} = Diâmetro à altura do peito de cada árvore medido em campo no inventário;

DBH_{est} = Diâmetro estimado em função das características altura e raio de copa médio, para dados *LiDAR* ou de inventário;

n = Tamanho da amostra dado pelo filtro no valor do diâmetro.

Este experimento foi realizado no intuito de avaliar a influência do nível de incerteza na qualidade das estimativas de diâmetro em função das alturas ou raios de copa médios medidos no inventário e extraídos dos dados *LiDAR*.

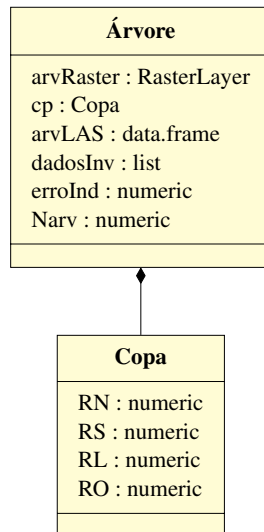
4 RESULTADOS E DISCUSSÃO

O processo de correspondência entre características proposto foi realizado com sucesso. Este processo resultou na representação conjunta dos dados de inventário florestal e nuvem de pontos 3d *LiDAR*. Os dados complementares foram estruturados na forma de objetos (Figura 6). Cada objeto representa uma árvore. As informações encapsuladas nesse objeto são dadas por:

- *arvRaster* = *Raster* da região com 25 m^2 tendo como centro o *keypoint* que define a posição da árvore com menor *idx* calculado;
- *cp* = Objeto que contém as informações dos raios de copa dadas as direções norte, sul, leste e oeste extraídas dos dados *LiDAR*;
- *arvLAS* = Nuvem de pontos 3d da região com 25 m^2 tendo como centro o *keypoint* que define a posição da árvore com menor *idx* calculado;
- *dadosInv* = Lista contendo as informações do inventário florestal de cada árvore;

- *erroIdx* = Valor do *idx* para cada árvore;
- *Narv* = Número da árvore do inventário florestal para controle.

Figura 6 – Representação da classe árvore obtida após processamento de dados por meio da correspondência por características.




Fonte: Elaborada pelo autor.

Na Figura 7a está apresentado um exemplo de aplicação do método proposto neste estudo. É possível verificar que existe uma representação específica de *keypoint* para cada árvore correspondente do inventário. O nível de incerteza define a precisão da correspondência por meio do valor do índice *idx*. Este conhecimento pode favorecer várias aplicações e trazer benefícios para o manejo florestal de precisão, pois pode-se ter controle sobre a incerteza. Com a técnica proposta, pode-se tanto ajustar modelos complementares, que utilizam dados de fontes diferentes como inventário e *LiDAR*, quanto possibilitar o uso de um parâmetro para avaliar a performance em estudos envolvendo dados *LiDAR*.

Em contrapartida, nos processos descritos por Popescu e Wynne (2004), Tiede, Hochleitner e Blaschke (2005) (Figura 7b), não é possível saber ao certo qual conjunto *keypoint* e copa extraída remetem à qual árvore do inventário, o que dificulta o uso dessas informações de forma complementares. O número de árvores possivelmente abrangidas por uma copa extraída, depende da detecção adequada do número de árvores realizada na definição da função de janela de busca. A detecção do número de árvores por meio dessa técnica tende a ser subestimado (GÖRGENS et al., 2015), o que pode dificultar a aplicação deste método, principalmente em áreas que não se tem o conhecimento prévio do número de árvores por hectare.

As técnicas para extração de árvores e copas de dados *LiDAR* descritas por Popescu, Wynne e Nelson (2002), Tiede, Hochleitner e Blaschke (2005) tendem a apresentar bons resultados para regiões com predominância de espécies que têm as copas bem definidas ou possuem espaçamento significativo entre árvores. Desta forma, o índice de incerteza proposto neste tra-

Figura 7 – Resultados da aplicação do método de correspondência de características proposto (a) e aplicação da detecção de máximos locais e copa pelo método de (POPESCU; WYNNE, 2004; TIEDE; HOCHLEITNER; BLASCHKE, 2005) (b) para uma mesma região.



Fonte: Elaborada pelo autor.

balho tende a ter uma boa aplicabilidade para correlacionar dados de inventário com dados *LiDAR*, principalmente em regiões de floresta densa, sendo possível a discriminação de mais características no processo. Nesse sentido, a precisão do *feature matching* pode ser melhorada se forem extraídas da nuvem de pontos 3d mais características possíveis de serem inventariadas. Como exemplo: Classificação do dossel quanto a luz, tipo de espécie, análises de contexto, etc.


Na Figura 8 é apresentada a relação entre a incerteza (*idx*) e o erro quadrático médio calculado para as características altura e raio de copa médio. Foi possível observar que a precisão da correspondência entre características está diretamente relacionada ao nível de corte no valor de incerteza. Quanto menor é o nível de incerteza maior é a precisão da correspondência entre características.

Observou-se que a precisão da extração da altura dos dados *LiDAR* foi maior do que a extração do raio de copa médio (Figura 8), dados os baixos níveis de erro quadrático médio apresentados na análise da característica altura em relação ao raio de copa médio. Além disso, o erro quadrático médio relacionado às características altura e raio de copa médio tendeu a reduzir com maior intensidade para níveis de incerteza abaixo de 1.5.

Foi avaliado o tamanho do efeito *d de Cohen* visando expressar a magnitude da diferença entre grupos definidos pelos filtros propostos para os níveis de incerteza preestabelecidos, em relação às características altura e raio de copa médio, conforme apresentado na Tabela 3.

De acordo com Cohen (1988.), os valores do *d de Cohen* são considerados insignificantes para $d < 0.19$, o que ocorreu em todos os casos para as características altura e raio de

Figura 8 – Erro quadrático médio em relação ao nível de incerteza aferido pelo índice de incerteza entre as características altura e raio de copa médio.



Fonte: Elaborada pelo autor.

Tabela 3 – Efeito *d* de Cohen para as características altura e raio de copa médio, dadas as variações nos cortes do $idx \leq 5$; $idx \leq 1$ e $idx \leq 0.5$.

Variável	<i>n</i>	<i>Média_{Inv}</i>	<i>Média_{Las}</i>	<i>Variância_{Inv}</i>	<i>Variância_{Las}</i>	<i>d</i> Cohen
Altura $Idx \leq 5$	1538	27.11	26.66	91.54	92.18	0.0476
Altura $Idx \leq 1$	1023	28.23	27.91	62.33	62.25	0.0404
Altura $Idx \leq 0.5$	546	28.33	28.09	49.17	49.21	0.0340
copa $Idx \leq 5$	1538	3.37	3.37	2.55	1.64	0.0042
copa $Idx \leq 1$	1023	3.35	3.35	1.73	1.44	0.0020
copa $Idx \leq 0.5$	546	3.23	3.26	1.3	1.18	0.0268


Fonte: Elaborada pelo autor.

copa médio. Além disso, foi possível observar que, quanto menor o nível de incerteza, menores foram os tamanhos dos efeitos, ou seja, a diferença das características entre as abstrações de dados estudadas foram menores para cortes mais restritivos no valor de *idx*.

Observou-se que, o nível de corte no valor do *idx* tem relação direta com o número de árvores remanescentes na base de dados. Ao se considerar a necessidade de maior precisão na correspondência ente características, haverá redução no número de árvores na base de dados de amostras. Na Figura 9 é apresentada a relação obtida entre o número de árvores na base de dados e o valor de corte no *idx*.

Outro fator responsável pela redução de árvores na base de dados foi dado pela sobreposição de pontos. Alguns *keypoints* acabaram por remeter à posição de uma mesma árvore do inventário. Nos casos que ocorreram a sobreposição, foram mantidos os *keypoints* que obtiveram menores valores de incerteza, sendo que, as demais árvores foram descartadas. O

Figura 9 – Número de árvores na base de dados em relação ao valor do índice de incerteza *idx*.



Fonte: Elaborada pelo autor.

nível de sobreposição observado foi de 27,25%, ou seja, a base de dados foi reduzida de 2143 árvores para 1559. São necessárias análises de contexto para tentar reduzir a sobreposição.

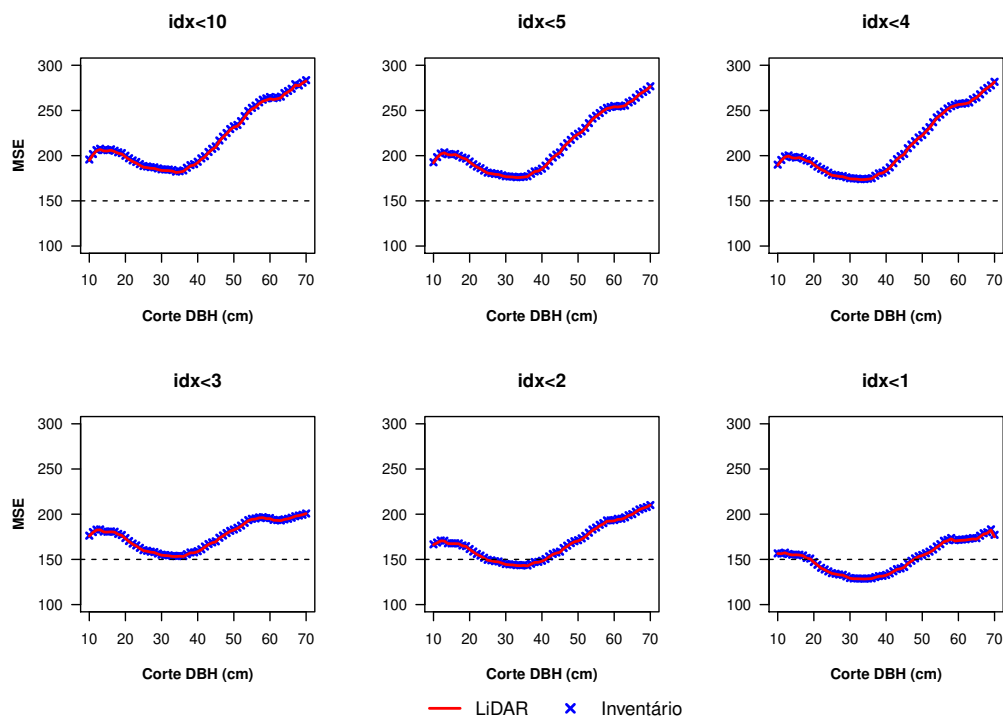
Os resultados do experimento para avaliar a influência da incerteza, por meio da modelagem estatística do diâmetro das árvores em função da altura, são apresentados na Figura 10. Com esse experimento, pode-se constatar que a altura extraída do *LiDAR* pode ser considerada equivalente à altura medida em campo, pois não houve diferença significativa entre os erros quadráticos médios obtidos nos ajustes utilizando os dados extraídos do *LiDAR* e medidos no inventário florestal.

Já os resultados observados em relação a modelagem do diâmetro em função do raio de copa médio, indicaram que o índice de incerteza proposto influenciou de forma significativa na precisão dos ajustes (Figura 11). Quanto menor o valor do *idx*, os erros quadráticos médios resultantes dos ajustes utilizando os dados extraídos do *LiDAR* tendem a se aproximar dos erros quadráticos médios obtidos pelos ajustes realizados com os dados do inventário.

Ao se avaliar a distribuição da altura das árvores, medidas em campo (*inv*) e também extraídas das nuvens de pontos 3d (*las*), em relação ao diâmetro à altura do peito (DBH) apresentadas na Figura 12, fica evidenciado que, após o processamento da correspondência de características os dados seguem uma distribuição semelhante, tal como era esperado.

Foi possível observar que quanto menor é o corte no *idx* menor é o erro entre as abstrações de dados referentes à altura das árvores. Como o *LiDAR* representa os dados de um ponto de vista superior do dossel, árvores com alturas inferiores à 15 metros tenderam a ser subestimadas pelo *LiDAR* (Figura 13). De uma maneira geral, as alturas extraídas do *LiDAR* tendem a ser menores do que as alturas observadas em campo no inventário florestal (PIRES, 2005). De acordo com Oliveira et al. (2014), isso ocorre por conta do *footprint* da varredura laser, que na maioria dos casos não possui precisão suficiente para mapear o topo da copa. De maneira geral, o *LiDAR* sub-amostrou as alturas, conforme esperado.

Figura 10 – Resultados das variações no *idx* em relação a modelagem estatística do diâmetro em função das alturas *LiDAR* e medidas no inventário florestal.



Fonte: Elaborada pelo autor.

Conforme apresentado na Figura 14, quanto menor o valor do índice de incerteza, mais a distribuição dos raios de copa médio se aproxima da tendência de distribuição dos raios de copa médio medidos no inventário.

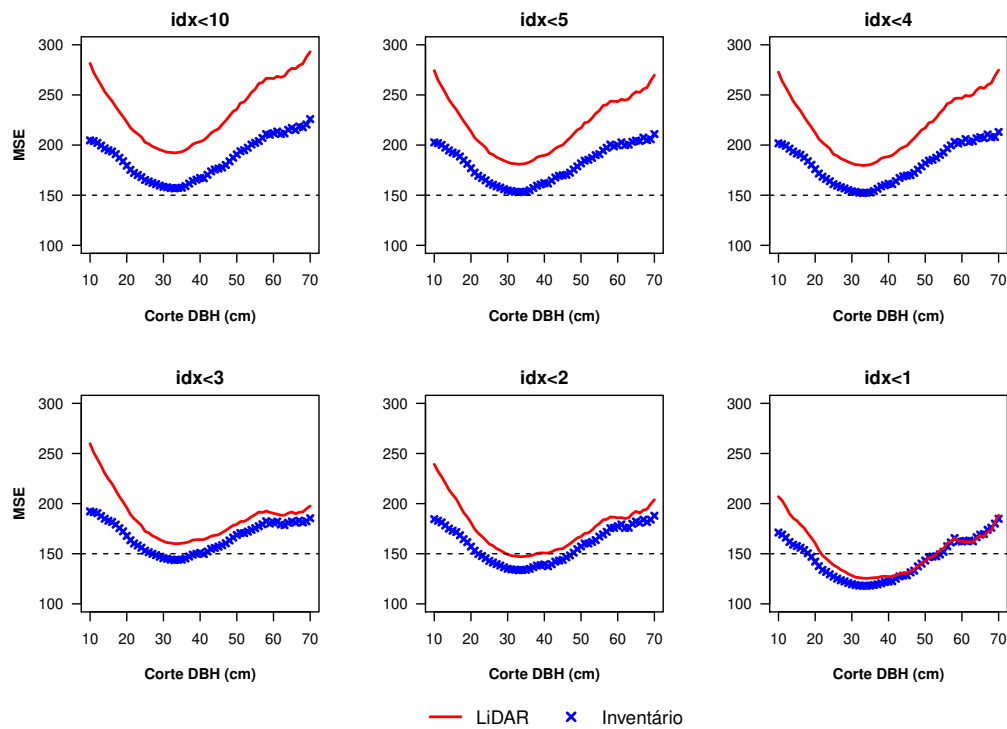
Ao se avaliar a dispersão dos resíduos referentes aos raios de copa na Figura 15, fica evidenciado que os erros da característica copa foram elevados ao correlacionar os dados de inventário com os dados *LiDAR*. Mesmo que, quanto menor o corte *idx* esse erro tenha a tendência a reduzir, ainda sim, novas propostas para melhorias na extração da copa na nuvem de pontos *LiDAR* devem ser avaliadas.

Wulder, Niemann e Goodenough (2000) relatam que o algoritmo proposto por Curran e Atkinson (1998) apresenta dificuldades para produzir bons resultados em áreas de florestas densas. O mesmo parece acontecer com o a adaptação proposta deste algoritmo, pois as variações das alturas *pixel a pixel*, em alguns casos avaliados, não atenderam ao critério de parada e retornaram erros elevados na avaliação entre os raios de copas de árvores.

Outros fatores que podem também estar associados aos altos erros obtidos na correlação da característica raio de copa:


- O erro não amostral relacionado à aferições de medidas em campo, devido a dificuldade operacional para medir os raios de copa com precisão. Principalmente dificultado pelo dossel fechado e até mesmo pelo acesso;

Figura 11 – Resultados das variações no *idx* em relação a modelagem estatística do diâmetro em função do raio de copa médio extraído do *LiDAR* e medido no inventário florestal.



Fonte: Elaborada pelo autor.


Figura 12 – Gráfico de dispersão entre a altura das árvores x DBH.



Fonte: Elaborada pelo autor.

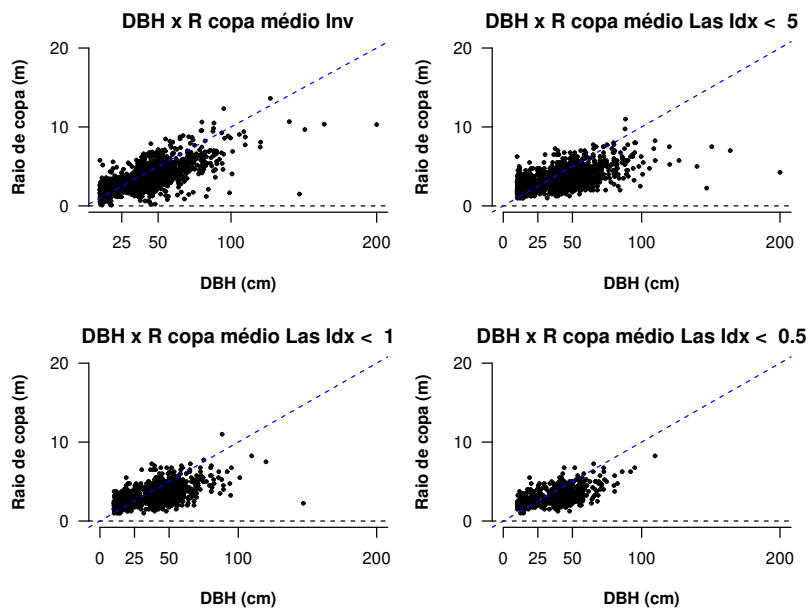
- As células que representam a resolução do MDS foram configuradas como 1 x 1 metro, propiciando que o algoritmo usado na extração dos raios de copas tivesse como característica o passo discreto. Assim sendo, o erro pode ter sido aumentado pela representação

Figura 13 – Dispersão de resíduos entre a altura obtida pelo modelo LiDAR e a variável altura do inventário florestal para todos dados e após cortes no Idx .



Fonte: Elaborada pelo autor.

Figura 14 – Gráfico de dispersão entre o raio de copa médio x DBH.




Fonte: Elaborada pelo autor.

de dados contínuos de forma discreta, o mesmo fato foi relatado por Wulder, Niemann e Goodenough (2000).

Ao se avaliar a composição média do índice de incerteza, a variável raio de copa médio se apresentou com representatividade baixa em relação aos componentes altura e distância, que obtiveram medianas e variabilidade equiparadas conforme apresentado na Figura 16. A composição do índice de incerteza denotou maior importância para a característica distância entre os *keypoints* e as árvores do inventário. A característica raio de copa foi mantida no processo


Figura 15 – Dispersão de resíduos entre os raios médios de copa obtidos por meio do LiDAR e inventário florestal em relação ao diâmetro medido em campo para diferentes cortes no Idx .



Fonte: Elaborada pelo autor.

proposto no intuito de auxiliar na correspondência entre características. Quanto mais próxima for a medida do raio de copa médio entre as diferentes fontes de dados, maior a chance das representações ou abstrações dos dados pertencerem à mesma árvore.

Figura 16 – Boxplot da composição percentual do idx dada cada uma das características estudadas.



Fonte: Elaborada pelo autor.

Foram realizados estudos com filtros de detecção de bordas: Canny e Sobel (DAUGMAN, 1985; CANNY, 1986), aplicados diretamente sob a imagem *raster* da região em estudo, visando delimitar os raios de copa. Após vários testes, foi possível constatar que a forma de extração do raio de copa proposta nesse estudo obteve melhores resultados do que a aplicação desses filtros. Os resultados foram avaliados em comparação com os raios de copa medidos no inventário florestal.

Podem haver outras fontes de incerteza que atuam no processo de correspondência

de características que não foram contempladas diretamente pelo índice de incerteza proposto. Algumas dessas fontes de incerteza são: - O erros não amostrais das medidas em campo como altura, raio de copa e marcação de coordenadas GPS, que se agravam num cenário de floresta densa ou dossel fechado; - A função de janela de busca do algoritmo LMF, que impacta na intensidade de *keypoints* e consequentemente se torna uma fonte de incerteza que pode vir a ser controlada; - A modelagem digital de terreno, que afeta diretamente a precisão da altura das árvores extraídas dos dados *LiDAR*; - Os algoritmos de extração do raio de copa dos dados *LiDAR*, que tendem a denotar baixa precisão.

Estudos com o enfoque de melhoria ou diminuição dessas fontes de incerteza podem otimizar significativamente o casamento de informações entre dados de campo e nuvem de pontos 3d obtidas do *LiDAR*.

5 CONCLUSÕES

Por meio do índice de incerteza proposto neste estudo, foi possível realizar a correspondência entre características extraídas de nuvens de pontos 3d obtidas do escaneamento por laser aerotransportado e dados de inventário.

Ao restringir o nível de incerteza na aplicação do processo de correspondência entre características proposto neste trabalho, foi obtida uma base de dados de árvores, composta por informações complementares entre dados do inventário florestal e nuvens de pontos 3d, com alto nível de precisão. Cortes mais restritivos nos valores do índice de incerteza, definem maior precisão na correspondência entre características, porém, remetem à redução das amostras de árvores na base de dados.

O índice de incerteza proposto favorece aplicações do manejo florestal de precisão, pois se apresenta como um parâmetro de validação da precisão, e pode ser utilizado para avaliar processos relacionados ao casamento entre dados de inventário e dados *LiDAR*.

Novos estudos com o enfoque na inserção de outras características no processo de correspondência entre dados obtidos do escaneamento por laser aerotransportado e dados do inventário florestal, assim como, melhorias nos processos de extração de características das nuvens de pontos 3d podem tornar o método proposto mais preciso.

**MAPEAMENTO DO POTENCIAL MADEIREIRO NUMA ÁREA DE FLORESTA AMAZÔNICA POR
MEIO DO ESCANEAMENTO POR LASER AEROTRANSPORTADO**

2 MAPEAMENTO DO POTENCIAL MADEIREIRO NUMA ÁREA DE FLORESTA AMAZÔNICA POR MEIO DO ESCANEAMENTO POR LASER AEROTRANSPORTADO

RESUMO

Um dos grandes problemas relacionados à exploração madeireira em áreas de floresta amazônica é que a metodologia atual de determinação do potencial produtivo para a elaboração de planos de manejo resulta frequentemente em intervenções desnecessárias, dimensionamento equivocado de pátios em termos da regulação florestal, e estimativa errônea do estoque e de unidades de produção. Isto ocorre, em muitos casos, em decorrência da falta de informação prévia para definição inicial das unidades de trabalho, o que dificulta a otimização do dimensionamento em função da regulação florestal. Com os avanços no sensoriamento remoto, principalmente pelo crescimento da utilização da tecnologia *LiDAR* no setor florestal, surge a proposta de mapear o potencial madeireiro em áreas de floresta amazônica, possibilitando a determinação espacialmente explícita do potencial produtivo de áreas específicas, bem como das árvores de interesse de manejo florestal. O processo geral é dado pela filtragem dos dados utilizando-se técnicas da visão computacional e modelagem estatística do diâmetro por meio da altura extraída das nuvens de pontos 3d, até serem obtidas árvores de interesse para o manejo florestal. Foram então realizados dois processos. O primeiro visa a avaliação dos resultados em relação à localização remota das árvores amostradas no inventário florestal. No segundo processo, foi realizada a análise do mapeamento do potencial madeireiro em relação ao dimensionamento de unidades de produção anual. Foram localizadas 32% das árvores com diâmetro superior à 50 *cm* em relação aos dados de inventário florestal. Pode-se alcançar níveis de localização na ordem de 60% caso sejam utilizadas folgas no método. O mapeamento do potencial produtivo realizado neste estudo pode prover informações relevantes para o dimensionamento das unidades de produção anual e, conseqüentemente, podem favorecer o planejamento de UPAs com enfoque na regulação florestal. Deste modo, foi possível obter informações importantes para o manejo florestal de precisão e uso sustentável dos recursos florestais.

Palavras-chave: Manejo florestal de precisão. Modelagem diamétrica. Visão computacional. *LiDAR*.

2 MAPPING OF LOGGING POTENTIAL IN AN AMAZON FOREST AREA BY AIR-BORNE LASER SCANNING

ABSTRACT

One of the major problems related to logging in areas of Amazon forest is that the current methodology for determining the productive potential for the elaboration of management plans often results in unnecessary interventions, wrong design of yards in terms of forest regulation, erroneous estimation inventory and production units. This occurs, in many cases, due to the lack of previous information for the initial definition of the work units, which makes it difficult to optimize the sizing due to forest regulation. With the advances in remote sensing, mainly due to the growth in the use of technology in the forestry sector, a proposal is presented to map the potential wood of areas of Amazon forest, making possible the spatially explicit determination of the productive potential of specific areas as well as the trees of interest in forest management. The general process is given by filtering the data using computational vision techniques and statistical modeling of the diameter. The data were filtered until trees of interest to the forest management were obtained. Two processes were performed. The first is to evaluate the results in relation to the remote location of the trees sampled in the forest inventory data. In the second process, an analysis was carried out of the mapping of the timber potential in relation to the design of annual production units. 32% of the trees with a diameter greater than 50 *cm* were found in relation to the forest inventory data. Localization levels of the order of 60% can be achieved if gaps are used in the method. The mapping of the productive potential carried out in this study can provide information relevant to the design of the annual production units, and consequently can favor the planning of units with a focus on forest regulation. In this way, it was possible to obtain important information for the forest management of precision and sustainable use of forest resources.

Keywords: Precision forest management. Diametric modeling. Computer vision. *LiDAR*.

1 INTRODUÇÃO

Na Amazônia Brasileira o manejo florestal sustentável tem-se consolidado como uma alternativa econômica de baixo impacto ambiental. De acordo com SNIF (2019), o manejo florestal sustentável consiste na administração da floresta visando o uso consciente dos recursos econômicos, sociais e ambientais, atentando para os mecanismos de sustentação do ecossistema a ser manejado (SNIF, 2019).

No Brasil, a exploração legal dos recursos florestais só pode ser realizada sob regime sustentável, por meio do desenvolvimento e aprovação do Plano de Manejo Florestal Sustentável (PMFS). Em 2009, foram estabelecidos critérios técnicos a serem adotados nos PMFS (Conselho Nacional do Meio Ambiente - CONAMA, 2009). Dentre os critérios definidos nesta resolução define-se que a exploração madeireira só pode ocorrer para árvores com diâmetro superiores a 50 *cm*.

Reis et al. (2013) relatam que os processos iniciais para se realizar o manejo florestal sustentável são dados pela definição das unidades de trabalho (UT) e realização do inventário 100%, ou seja, inventário caracterizado pelo censo.

Um dos grandes problemas relacionados à exploração madeireira em áreas de floresta amazônica é que a metodologia atual de determinação do potencial produtivo para a elaboração de planos de manejo resulta frequentemente em intervenções desnecessárias, dimensionamento equivocado de pátios em termos da regulação florestal, e estimativa errônea do estoque e de unidades de produção.

De acordo com Leuschner (1984), numa floresta regulada, em cada ano ou ciclo de corte, o volume de produção, o tamanho da área colhida e a qualidade dos produtos são equalitários. Leite et al. (2016) relatam que a divisão das unidades de trabalho em compartimentos de igual tamanho não garante uma distribuição regular de volume, renda e ou espécies.

A distribuição espacial das unidades de produção anual (UPA) não é um processo simples de ser realizado, pois tem relação direta com o nível de exploração madeireira por compartimento, e essa escolha afeta diretamente a qualidade da regulação florestal. A escolha e dimensionamento das unidades de produção anual em florestas nativas é um problema que requer solução otimizada (SOUZA; SOARES, 2013).

Por outro lado, o *LiDAR* aerotransportado é uma tecnologia que vem despontando em diversas aplicações no setor florestal. De acordo com Zonete (2009), os sistemas *LiDAR* aerotransportado permitem o mapeamento de vastas áreas florestais com alto nível de precisão. A tecnologia *LiDAR* pode ser considerada atrativa para o mapeamento de características importantes para o manejo florestal como a altura das árvores e informações de copas (POPESCU; WYNNE; NELSON, 2002; TIEDE; HOCHLEITNER; BLASCHKE, 2005).

O *LiDAR* permite uma visão superior do dossel de uma floresta, mas não permite a detecção direta do diâmetro das árvores. Uma relação muito comum de ser observada em estudos com dados *LiDAR* é dada entre a altura e variáveis dendrométricas (ZANDONÁ; LINGNAU;

NAKAJIMA, 2008), isto é muito relevante pois, a altura é uma variável que é facilmente obtida por meio dos dados *LiDAR*.

Oliveira et al. (2014) utilizaram modelos para relação hipsométrica, de forma inversa para obter o diâmetro em função das alturas das árvores extraídas dos dados *LiDAR*, e obtiveram resultados com bons níveis de precisão. Em áreas de floresta amazônica, a altura das árvores é de difícil mensuração, devido ao dossel da floresta ser muito fechado na maioria dos casos. Assim, alternativas como a tecnologia *LiDAR* podem ser utilizadas para amostrar as alturas de árvores, e esses dados podem ser correlacionados com dados de campo, como por exemplo o diâmetro medido em campo.

Técnicas da visão computacional podem ser utilizadas para definir a intensidade de incerteza da correspondência de características entre dados *LiDAR* e dados do inventário florestal (PELLI; GÖRGENS, 2019, no prelo). Ao se controlar a incerteza no casamento dessas informações, pode-se otimizar a modelagem diamétrica em função das alturas extraídas dos dados *LiDAR*. Além disso, a incerteza pode ser utilizada como parâmetro para validação de processos de localização de árvores e avaliação de modelos.

2 OBJETIVO

Propor metodologia para mapeamento do potencial madeireiro em floresta amazônica por meio do escaneamento por laser aerotransportado, possibilitando a determinação espacialmente explícita do potencial produtivo de áreas específicas bem como das árvores de interesse de manejo florestal.

3 MATERIAL E MÉTODOS

Os dados utilizados para testar a metodologia foram obtidos de uma área de manejo florestal pertencente à empresa CIKEL Brasil Verde Madeira Ltda., localizada na fazenda Cauaxi, município de Paragominas, Estado do Pará, Brasil. Como relatado por Keefe et al. (2009), a floresta é constituída por vegetação natural típica classificada como floresta ombrófila densa. Os solos predominantes são latossolos amarelo distróficos e a topografia varia de plana a suave-ondulada, com altitude de 119 metros (GÖRGENS et al., 2016).

Em 2012, foi realizado o inventário florestal na área e foram coletados dados *LiDAR* de alta precisão pelo Serviço Florestal dos Estados Unidos, em colaboração com a Empresa Brasileira de Pesquisa Agrícola (EMBRAPA).

Foram avaliadas 22 parcelas com área de 20x500 m, com sobreposição de sub-parcelas com área de 2x500 m, seguindo uma amostragem sistemática, com início aleatório. Árvores com diâmetro à altura do peito (*DBH*) igual ou superiores à 35 cm foram medidas dentro da área da parcela. Na sub-parcela, foram medidas árvores com *DBH* igual ou superiores à 10 cm e inferiores à 35 cm. Na Tabela 4 é apresentado o resumo dos dados do inventário florestal.

Tabela 4 – Análise descritiva dos dados do inventário florestal.

	Variável	n	Min	Max	Média	Desvio Padrão
<i>DBH</i> < 35 cm	<i>DBH</i>	1124	10.00	34.90	17.57	6.39
	<i>Ht</i>	1124	1.31	56.40	17.80	7.02
	<i>RaioCopa</i>	4496	0.00	17.00	2.15	1.31
<i>DBH</i> ≥ 35 cm	<i>DBH</i>	1425	35.00	200.00	50.49	16.24
	<i>Ht</i>	1425	1.85	71.22	31.02	9.30
	<i>RaioCopa</i>	5700	0.00	21.50	4.06	2.21

Fonte: Elaborada pelo autor.

As 15 principais espécies com os maiores índices de valor de importância (*IVI*) encontradas nas 22 parcelas do inventário florestal estão listadas na Tabela 5. Foram analisados apenas os indivíduos com diâmetro igual ou superior à 50 cm. Foram apresentados os valores para densidade (*DA* e *DR*), frequência (*FA* e *FR*) e dominância (*DoA* e *DoR*) absolutas e relativas respectivamente, o índice do valor de cobertura (*IVC*) e a classificação de espécie madeireira de interesse comercial.

Tabela 5 – Lista em ordem decrescente das 15 espécies com maior valor de *IVI* amostradas no inventário florestal para indivíduos com diâmetro igual ou superior à 50 cm.

Espécie	FA	FR	DA	DR	DoA	DoR	IVC	IVI	Comercial
<i>Pouteria gongrijpii</i>	63.64	3.78	1.77	7.69	0.58	7.09	7.39	6.19	N
<i>Manilkara huberi</i>	77.27	4.59	1.14	4.93	0.49	6.06	5.49	5.19	S
<i>Eschweilera coriacea</i>	72.73	4.32	1.32	5.72	0.32	3.96	4.84	4.67	S
<i>Pouteria</i> sp.	59.09	3.51	0.95	4.14	0.27	3.35	3.75	3.67	N
<i>Tachigali myrmecophila</i>	59.09	3.51	0.86	3.75	0.29	3.61	3.68	3.62	N*
<i>Manilkara bidentata</i>	50.00	2.97	0.86	3.75	0.31	3.84	3.79	3.52	S
<i>Tetragastris panamensis</i>	40.91	2.43	0.91	3.94	0.23	2.77	3.36	3.05	N
<i>Pouteria oppositifolia</i>	50.00	2.97	0.68	2.96	0.19	2.32	2.64	2.75	N
<i>Lecythis lurida</i>	40.91	2.43	0.59	2.56	0.25	3.05	2.81	2.68	S
<i>Dinizia excelsa</i>	22.73	1.35	0.23	0.99	0.38	4.63	2.81	2.32	S
<i>Eschweilera ovata</i>	40.91	2.43	0.55	2.37	0.16	1.98	2.17	2.26	N
<i>Pouteria hispida</i>	40.91	2.43	0.55	2.37	0.14	1.73	2.05	2.18	N
<i>Tetragastris altissima</i>	27.27	1.62	0.59	2.56	0.15	1.83	2.20	2.01	N
<i>Astronium graveolens</i>	31.82	1.89	0.36	1.58	0.19	2.35	1.96	1.94	S
<i>Couratari stellata</i>	36.36	2.16	0.45	1.97	0.12	1.49	1.73	1.88	S

Fonte: Elaborada pelo autor.

De acordo com o Serviço Florestal Brasileiro (SNIF, 2019), das 96 espécies amostradas com diâmetro acima de 50 cm no inventário florestal, 32 foram consideradas espécies madeiras de interesse comercial. Ou seja, a taxa de espécies que remetem ao potencial madeireiro encontrada no inventário florestal é dada por 33,33%.

Em julho de 2012 foi realizado o sobrevôo *LiDAR* sobre a fazenda Cauaxi. De acordo com Pinagé et al. (2015), as características de aquisição da nuvem de pontos é apresentada na Tabela 6.

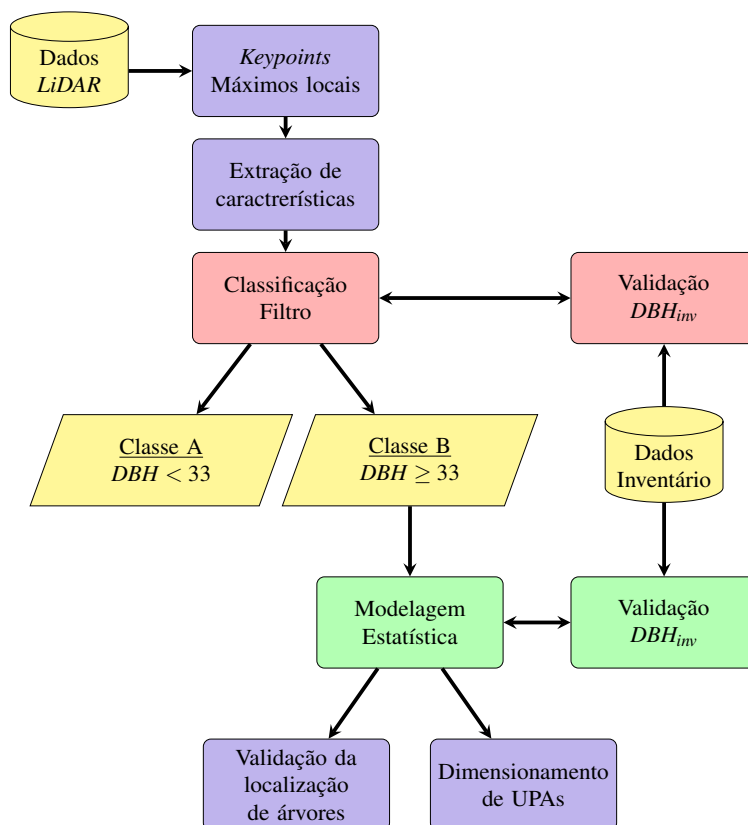
* Espécie não catalogada pelo Serviço Florestal Brasileiro de acordo com a classificação de espécie madeira de interesse comercial.

Tabela 6 – Parâmetros da aquisição da nuvem de pontos.

Característica	Dado
Equipamento	Optech ALTM 3100
Data de aquisição	27-29/07/2012
Área total	1214 ha
Altitude máxima de voo (em relação ao terreno)	850 m
Campo de visada	11°
Frequência de pulso	100 KHz
Densidade mínima de retornos	4/ m ²
Densidade média de retornos	28.3/m ²
Densidade média de primeiros retornos	13.8/m ²

Fonte: Adaptada de Pinagé et al. (2015).

A metodologia proposta neste trabalho (Figura 17) tem enfoque em duas etapas: - Na primeira etapa, buscou-se localizar espacialmente árvores do ponto de vista do potencial madeireiro, para isso, foi necessária a obtenção indireta do diâmetro por meio dos dados *LiDAR*. Para avaliar e validar os resultados da localização das árvores foram utilizados parâmetros de incerteza em relação aos dados do inventário florestal; - Na segunda etapa, foram utilizadas as informações de intensidade de árvores localizadas como base para a localização e dimensionamento das unidades de produção anual.

Figura 17 – Fluxograma da metodologia utilizada neste trabalho.

Fonte: Elaborada pelo autor.

3.1 Extração de *keypoints*

Do ponto de vista da visão computacional, objetos podem ser localizados em imagens por meio da análise de características específicas extraídas em pontos de interesse, nos quais essas características são pronunciadas ou significativamente diferenciáveis por meio de algum modelo matemático (FORSYTH; PONCE, 2003; SZELISKI, 2011).

Os pontos de interesse ou *keypoints* são dados por parte de uma imagem ou objeto, que representam características significativas e únicas, capazes de diferenciar estas imagens ou objetos sem a necessidade da análise completa. O conceito de *keypoint* pode otimizar a performance e a precisão de processamento das informações, tendo em vista que, se baseia no princípio da redução da dimensionalidade do problema, em que se espera que cada *keypoint* tenha relevância máxima e redundância mínima (DUDA; HART; STORK, 2001).

Para se localizar as árvores de interesse do manejo florestal nas nuvens de pontos 3d, foi preciso definir os *keypoints* a serem analisados, a fim de se verificar a correspondência com os dados de campo. Foi utilizado o algoritmo de máximo local (LMF), proposto por Popescu e Wynne (2004), para obtenção dos máximos locais por meio de filtro de janela de busca variável. Esse algoritmo, foi inicialmente proposto para localizar os picos de cada árvore dentre as regiões definidas pela janela de busca. Neste estudo específico, os pontos de máximos aferidos pelo algoritmo LMF foram atribuídos ao conceito de *keypoints*, no intuito de serem analisados de acordo com metodologia proposta.

O processo de extração dos *keypoints* teve início com obtenção do modelo digital de superfície (MDS) com resolução de 1 x 1 metros, tendo os dados *LiDAR* da área de estudo como entrada do processamento. Foram avaliadas diferentes funções de janela de busca, no intuito de se extrair do MDS uma amostragem de *keypoints* suficientes para se localizar árvores com diâmetro superiores à 50 cm. A função de janela de busca utilizada foi: $janela = \beta_0 + \beta_1 * H$ (sendo *janela* = janela de busca do algoritmo de máximo local LMF e *H* = à altura do modelo digital de superfície). Os parâmetros das diferentes funções de janela de busca avaliadas estão apresentados na Tabela 7.

Tabela 7 – Parâmetros pré-definidos para as diferentes funções de janela de busca avaliadas.

<i>janela de busca</i>	β_0	β_1
1	0.6	0.05
2	0.6	0.03
3	0.6	0.01

Fonte: Elaborada pelo autor.

A escolha da função de janela a ser utilizada no processo, se deu pela comparação entre a intensidade de árvores por hectare amostradas em campo e a intensidade de *keypoints* obtidos por meio da aplicação de cada função de janela de busca, associada ao algoritmo LMF. Além disso, foi avaliada a disposição espacial das árvores com diâmetro superiores à 50 cm

em relação aos *keypoints* obtidos, nas regiões das parcelas amostradas no inventário florestal. Objetivou-se na escolha da função de janela busca, obter *keypoints* suficientes para que, ao fim do processo proposto fosse possível localizar as árvores de interesse para o manejo florestal na região de estudo.

3.2 Extração de características

Para se identificar as árvores de interesse para o manejo florestal, dentre as nuvens de pontos 3d obtidas dos dados *LiDAR*, foi preciso definir as características descritoras capazes de diferenciar árvores de grande porte das demais. Deste modo, foram escolhidas as características descritoras: raio de copa médio, altura da árvore e índice de competitividade. Essa escolha se deu, pela possibilidade de extração dessas características nas nuvens de pontos 3d, diretamente sob os *keypoints* definidos no passo anterior.

Os raios de copa foram extraídos por meio de uma análise *pixel à pixel* nas direções direções norte (RN), sul (RS), leste (RL) e oeste (RO) tendo como início à coordenada do *keypoint* em análise. Foram avaliadas as variações nas elevações (Z), para cada par de *pixels*, usando a seguinte Equação: $Var_Z = (Z_{Pixel\ i} - Z_{Pixel(i-1)})^2$. O raio de copa foi definido no *pixel* em que a variação na elevação atinge o critério: $Var_Z > 1$ (PELLI; GÖRGENS, 2019, no prelo). A característica raio de copa médio foi então obtida, pela média aritmética dos raios extraídos nas direções norte, sul, leste e oeste. Os raios de copa médio extraídos foram limitados a valores menores ou iguais à 25 m, de acordo com os raios de copa máximos observados inventário florestal.

As alturas das árvores foram extraídas diretamente do modelo digital de superfície. Cada um dos *keypoints* foi centralizado numa janela de 25 m². A janela foi dividida em 4 quadrantes perfeitos. Em cada quadrante foi obtido a elevação mínima local referente ao eixo Z , ou seja, valores condizentes aos retornos mais longos obtidos do *LiDAR*. A altura extraída para cada *keypoint* foi então calculada pela Equação 16.

$$Ht_{kp} = Z_{kp} - \frac{(Quad_1[Z_{min}] + Quad_2[Z_{min}] + Quad_3[Z_{min}] + Quad_4[Z_{min}])}{4} \quad (16)$$

Em que:

$Quad_i[Z_{min}]$: Elevação mínima local, extraída no i – ésimo quadrante;

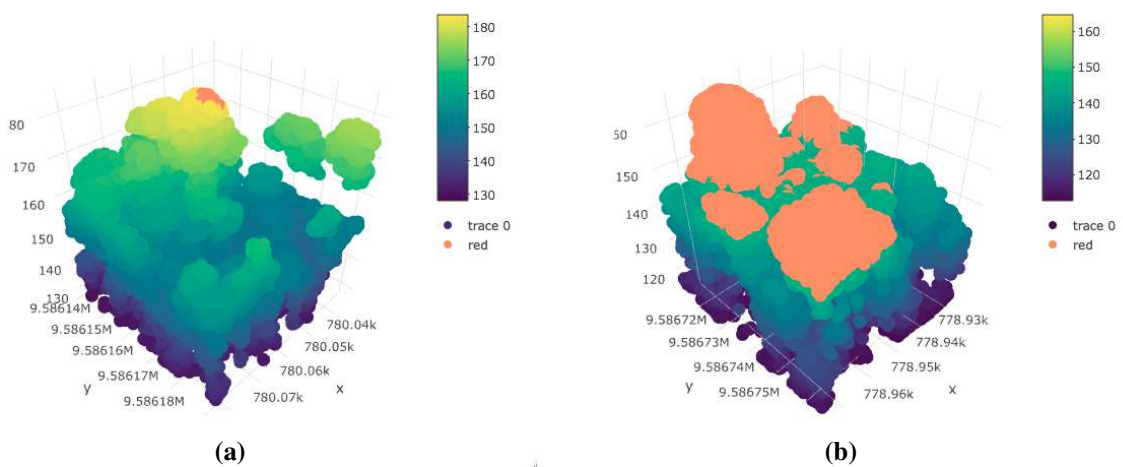
Z_{kp} : Elevação observada para cada *keypoint*.

A característica índice de competitividade foi abstraída para refletir o nível de supressão da árvore em relação à suas vizinhas. A altura de uma árvore tem relação direta com a sua capacidade competitiva, pois, árvores mais altas que suas vizinhas têm prioridade no acesso à luz (WESTOBY et al., 2002).

Deste modo, foi proposta a extração do índice de competitividade diretamente da nuvem de pontos 3d. Foram realizados cortes transversais e paralelos aos eixos X e Y , exatamente

sobre altura do ponto central no eixo Z, conforme apresentado na Figura 18. Foram então somados os registros de retornos de pulsos que ocorreram acima deste corte. Ou seja, foram somados os registros de pontos observados acima da altura do *keypoint* em análise, centralizado numa janela de 25 m^2 . Essa característica pode denotar o grau de dominância de uma árvore em termos de competitividade, perante às árvores vizinhas. Quanto menor é o valor do índice de competitividade, maior é o nível de dominância desta árvore, pois indica que ela recebe luz direta.

Figura 18 – Representação da característica definida como índice de competitividade. Árvore que recebe luz direta (a). Árvore com vizinhas mais altas (b).



Fonte: Elaborada pelo autor.

3.3 Classificação - Filtro

O parâmetro escolhido para diferenciar as árvores suprimidas ou de pequeno porte das árvores de interesse do manejo florestal foi o diâmetro à altura do peito (*DBH*). Foi proposta a divisão de classes dada por: CLASSE A: $DBH < 33$ e CLASSE B: $DBH \geq 33$. Essa escolha se deu por meio de avaliação exploratória dos dados consolidados entre *LiDAR* e inventário, com nível de incerteza de $idx \leq 0.75$ (PELLI; GÖRGENS, 2019, no prelo).

Foi proposto então, o treinamento de um classificador para filtrar a classes dados de $DBH < 33$ e $DBH \geq 33$, tendo como entradas as características raio de copa médio, altura da árvore e índice de competitividade.

Uma Máquina de Vetores-Suporte (*Support Vector Machine* - SVM) é um classificador que tem como objetivo a determinação de um hiperplano ideal por meio da minimização dos erros. A SVM utiliza o aprendizado supervisionado e é capaz de categorizar novos exemplos após a definição de um limite de decisão ótimo na fase de treinamento (VAPNIK, 1999).

Foi realizado um experimento para avaliar a precisão e a acurácia da classificação ao se aplicar a SVM na filtragem de *keypoints* por classes de diâmetros. Para tanto, foram utilizados

os dados correlacionados por meio da correspondência de características, com nível de incerteza: $idx \leq 0.75$. O modelo do classificador SVM foi planejado tendo como características de entrada o raio de copa médio, a altura e o índice de competitividade. As classes alvo foram definidas como Classe A ($DBH < 33$) e Classe B ($DBH \geq 33$).

Foram então realizadas 20 repetições do processo: escolher aleatoriamente 200 árvores de cada classe A e B; Em cada etapa do experimento foram definidos dois grupos de dados, o de treinamento com 280 árvores (70%), e o grupo de teste dado por 120 árvores (30%). Os grupos de treinamento foram utilizados para ajustar o classificador, que foi aplicado aos respectivos grupos de teste. A qualidade do ajuste foi avaliada por meio das médias da precisão e a acurácia calculadas ao se aplicar as Equações 17 e 18 (KOHAVI; PROVOST, 1998).

$$Precisão = \frac{Verdadeiros\ Positivos\ (VP)}{Verdadeiros\ Positivos\ (VP) + Falsos\ Positivos\ (FP)} \quad (17)$$

$$Acurácia = \frac{Verdadeiros\ Positivos\ (VP) + Verdadeiros\ Negativos\ (VN)}{Total} \quad (18)$$

Sendo avaliados de acordo com a matriz confusão apresentada na Tabela 8.

Tabela 8 – Matriz confusão.

		Observados		
		Positivos	Negativos	
Esperados	Positivos	VP	FN	VP + FN
	Negativos	FP	VN	FP + VN
		VP + FP	FN + VN	Total

Fonte: Kohavi e Provost (1998).

No intuito de se maximizar a acurácia do classificador SVM, foi realizada validação cruzada (*10-fold cross validation*) para ajuste dos parâmetros iniciais do classificador (ANGUITA; RIDELLA; RIVIECCIO, 2005). Foi utilizado o parâmetro núcleo (*kernel*) radial. O parâmetro custo (C) foi validado dentre as possibilidades com variação entre $C = \{0.1, 1, 10 \text{ e } 100\}$. E o parâmetro *gama* foi variado conforme $\gamma = \{0.5, 1, 2\}$. Para avaliar a qualidade dos modelos foi utilizada a taxa de acurácia média da classificação.

O classificador SVM foi treinado utilizando os dados de correspondência de características com nível de incerteza: $idx \leq 0.75$ e foi aplicado aos *keypoints* localizados na área de estudo. Desta forma, foi possível filtrar *keypoints* que remetem à possíveis árvores que não interessam na definição do potencial madeireiro.

3.4 Modelagem estatística

A tecnologia *LiDAR* não fornece diretamente o diâmetro das árvores. Neste estudo foram utilizados modelos estatísticos para estimar o diâmetro das árvores em função da altura

extraída dos dados *LiDAR*. Ou seja, os modelos testados e utilizados neste estudo têm como característica: $DBH \approx f(Ht_{LiDAR})$. Foram avaliados quatro modelos tradicionais, originalmente propostos para ser utilizados em relação hipsométrica, porém foram ajustados na suas formas inversas: modelo parabólico (A), $DBH = \beta_0 + \beta_1 \times Ht + \beta_2 \times Ht^2 + \varepsilon$; modelo da linha reta (B), $DBH = \beta_0 + \beta_1 \times Ht + \varepsilon$, modelo de Stofel (C), $Log(DBH) = \beta_0 + \beta_1 \times Log(Ht) + Log(\varepsilon)$; e modelo de Curtis (D), $DBH = \beta_0 + \beta_1 / Log(Ht) + \varepsilon$ (OLIVEIRA et al., 2014).

Para se ajustar esse tipo de modelo, a variável dependente necessita ser conhecida. Portanto, o ajuste e avaliação da modelagem estatística se deu por meio dos dados de correspondência de características com nível de incerteza $idx \leq 0.75$, em que a variável dependente diâmetro foi observada no inventário florestal. As avaliações de precisão dos ajustes foram realizadas pela análise da raiz do erro quadrático médio (*RMSE*), pela análise gráfica da dispersão do erro e pelo coeficiente de determinação (R^2).

Após a filtragem dos dados pelo classificador SVM, obtendo-se os *keypoints* classificados com o diâmetro superior ou igual a 33 cm (Classe B), foi aplicado o modelo diamétrico selecionado após avaliação, e assim, foi estimado o diâmetro das árvores da Classe B. Foram consideradas como árvores localizadas os *keypoints* que obtiveram $DBH \geq 50$ após aplicação do modelo estatístico.

3.5 Validação da localização das árvores

Para validar se as árvores foram localizadas foi proposta a varredura nas áreas das parcelas do inventário florestal, relacionando os *keypoints* localizados nestas regiões em relação à posição das árvores com diâmetro superiores à 50 cm amostradas no inventário.

Foi proposto um algoritmo para validação da localização de árvores em relação ao inventário florestal (Algoritmo 1). Neste algoritmo, para cada um dos *keypoints* mapeados dentro da parcela foi calculado o nível de incerteza (*idx*) em relação à cada uma das árvores com diâmetro superior a 50 cm, da respectiva parcela. Os conjuntos *keypoints* e árvores com menor *idx* observados foram armazenados.

A definição da localização das árvores foi dada pela aplicação de um filtro nos valores de *idx*, sob os dados armazenados. Este filtro representa o nível de incerteza aceito. A escolha do filtro foi realizada por meio da análise do número de árvores localizadas em relação

ao nível de incerteza obtido pelo algoritmo.

Algoritmo 1: VALIDAÇÃO DA LOCALIZAÇÃO DE ÁRVORES EM RELAÇÃO AO INVENTÁRIO FLORESTAL

Entrada: $Kps, dadosParcela$

Saída: Base de dados inventário correlacionada com kps localizados

```

1  início
2  para cada  $Kp_{loc} \in Parcela$  faça
3      para cada  $Arvore \in Parcela$  faça
4           $idx \leftarrow \text{CALCULAIDX}(Arvore, Kp_{loc})$ 
5           $vetor(Arvore) \leftarrow \text{CONCATENA}(Arvore, idx)$ 
6      fim
7       $ArvoreEscolhida \leftarrow \text{PEGAARVOREMENORIDX}(vetor(Arvore))$ 
8       $baseDados(Kp_{loc}) \leftarrow \text{CONCATENA}(ArvoreEscolhida, Kp_{loc})$ 
9       $Parcela \leftarrow \text{REMOVE}(ArvoreEscolhida, Parcela)$ 
10 fim
11 fim
12 retorna  $baseDados$ 

```

Fonte: Elaborado pelo autor.

De posse das árvores localizadas pelo algoritmo proposto, foi realizada uma nova análise estrutural da floresta no intuito de entender quais espécies foram encontradas no processo ao se utilizar os dados *LiDAR*.

3.6 Dimensionamento das Unidades de Produção Anual

A partir de dados de sobrevôos *LiDAR*, pode-se planejar o mapeamento das unidades de produção anuais com enfoque diferente do tradicional. As informações obtidas do *LiDAR* podem ser utilizadas para se realizar um pré-mapeamento do potencial madeireiro. Pode-se obter previamente à uma ida a campo, parâmetros como o número de árvores por hectare ou até mesmo a produção direta em m^3/ha por meio da metodologia proposta.

Dados *LiDAR* processados possibilitam a obtenção de informações de coordenadas e alturas extraídas diretamente de cada *keypoint*. A modelagem estatística do diâmetro torna possível o mapeamento do volume de madeira a ser explorado numa dada região.

O volume das árvores localizadas foi estimado utilizando o sistema de equações ajustados por Cysneiros et al. (2017), sendo que o modelo utilizado foi o de *Schumacher & Hall* (Equação 19) linearizado e estratificado em classes diamétricas. As classes de diâmetro pré-definidas para o sistema de equações e os parâmetros ajustados são apresentados na Tabela 9.

$$\ln Vol = \beta_0 + \beta_1 \times \ln DBH + \beta_2 \times \ln Ht + \varepsilon \quad (19)$$

Tabela 9 – Sistema de equações genérica para estimativa de volume de árvores com os respectivos coeficientes de regressão e coeficiente de ajuste por estratos diamétricos.

Classe de diâmetro (cm)	β_0	β_1	β_2	$R^2_{aj.}$
50 < 70	-6.60	1.45	0.69	0.420
70 < 90	-8.96	1.92	0.82	0.404
90 < 110	-11.42	2.45	0.83	0.344
110 < 130	-8.59	1.98	0.60	0.172

Fonte: Elaborada pelo autor.


Foi necessário o ajuste da variável altura extraída dos dados *LiDAR*, tendo em vista que o sistema de equações volumétricas estratificada por classes diamétricas (Tabela 9), foi ajustado levando-se em consideração as alturas das árvores do inventário florestal. Pires (2005), relata que as alturas das árvores extraídas do *LiDAR* tendem a ser sub-amostradas em relação às medidas de altura do inventário. Portanto, as alturas extraídas dos dados *LiDAR* foram ajustadas por meio da aplicação da Equação 20, proposta por Maltamo et al. (2004).

$$Ht_{ajustada} = \beta_0 + \beta_1 \times Ht_{LiDAR} + \varepsilon \quad (20)$$

Para se definir o dimensionamento das unidades de produção anual, visando um maior nível de precisão, é necessário ter conhecimento prévio do percentual de espécies comerciais encontrado na área de estudo. Deve-se também, levar em consideração a taxa de aproveitamento, sendo que, as árvores podem apresentar algumas imperfeições que denotem perda de valor econômico, como por exemplo árvores com galhos próximos ao solo, com fuste torto, quebradas, dentre outros problemas (REIS et al., 2013).

Neste trabalho, foi proposta a utilização do percentual de exploração (% Planejamento - Figura 19) que leva em consideração a taxa das árvores localizadas pelo *LiDAR* no processo anterior, o percentual de espécies comerciais pré-definido na área em estudo, e o percentual de aproveitamento da madeira.

Figura 19 – Definição dos percentuais de aproveitamento da madeira para planejamento de UPAs.



Fonte: Elaborada pelo autor.

Após a definição dos percentual de exploração, pode-se mapear de forma generalista as unidades de produção anual, caracterizando-se o potencial madeireiro médio que pode ser

extraído de cada UPA. Foi proposto um processo para estratificação das UPAs baseado na divisão da área dada pela distribuição espacial das árvores localizadas.

A técnica utilizada para mapeamento das unidades de produção anual foi o algoritmo *k-means*. Neste estudo foi utilizada a versão do algoritmo *k-means* proposta por Hartigan e Wong (1979). O algoritmo *k-means* é um método não hierárquico que divide um conjunto de dados N em k grupos disjuntos. Cada grupo é descrito pela média μ_j das amostras do agrupamento. Os pontos médios dos agrupamentos são chamados “centróides”). A partir daí, o algoritmo aloca cada elemento da análise ao agrupamento cujo ponto central (centróide) esteja mais próximo (DUDA; HART; STORK, 2001; ARTHUR; VASSILVITSKII, 2007).

Foi realizado um experimento com a proposta de que as divisões dadas por diferentes valores do parâmetro k remetam diretamente às unidades de produção a serem avaliadas. O experimento consistiu na variação de $k = \{2 : 20\}$. Para cada divisão em grupos pelo algoritmo *k-means*, dado o valor k , foram calculadas as seguintes características médias entre os grupos: - número de árvores componentes; - número de árvores por hectare; Produção total de volume por hectare; área em hectare e potencial madeireiro obtido por $m^3/ha_{total} \times Tx$ Planejamento. Essas informações podem ser utilizadas para se planejar o número de unidades de produção anual, ou então, a intensidade de exploração madeireira sustentável. Uma vez definido o valor de k , que neste caso remete diretamente ao número de unidades de produção, pode-se novamente aplicar o algoritmo *k-means* e se obter a localização e a discriminação do potencial madeireiro de cada UPA.

4 RESULTADOS E DISCUSSÃO

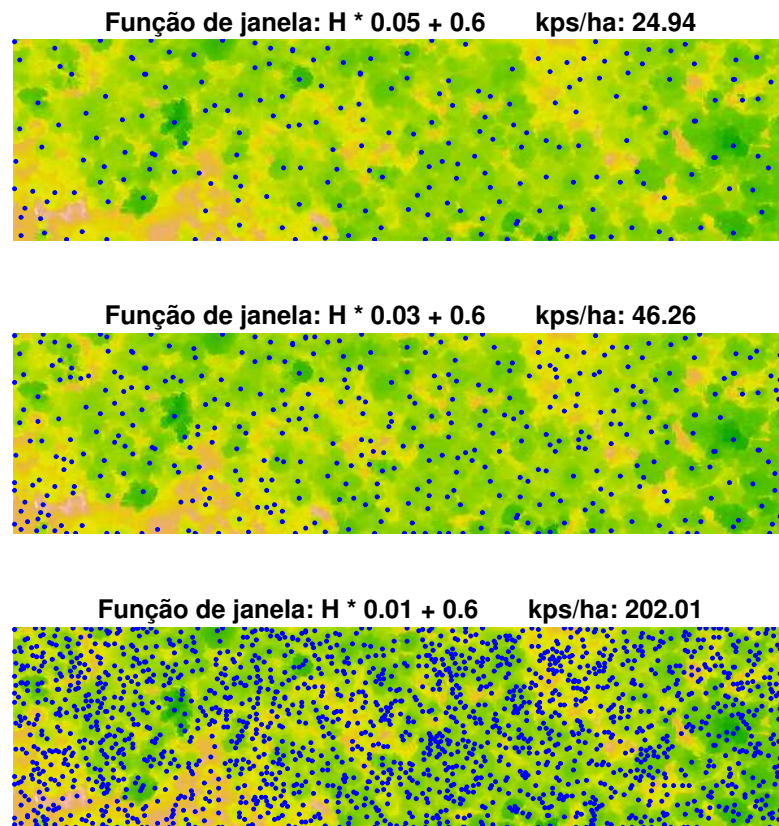
Popescu e Wynne (2004) relatam que as funções de janela de busca podem ser otimizadas se forem estratificadas em sistemas baseados em diferenciação de espécie ou espaçamento entre árvores. Por se tratar de área de floresta amazônica natural e densa, foram avaliadas funções de janela de busca que se assemelhavam à amostragem geral da dispersão espacial dos indivíduos componentes das parcelas do inventário florestal.

A função de janela de busca aplicada ao algoritmo de máximos locais define a intensidade de *keypoints* encontrados por área (LARSEN, 1999). Na Figura 20 são apresentadas as intensidades de *keypoints* amostrados pelas diferentes funções de janelas de busca avaliadas neste estudo.

A intensidade média de árvores com diâmetro superior à 50 cm amostradas nas parcelas do inventário florestal foi dada por 25.32 ± 7.96 árvores por hectare. Deste modo, foi escolhida a função de janela de busca: $H * 0.3 + 0.6$ por amostrar um número suficiente de *keypoints* (46.25 kps/ha) capaz de propiciar a localização árvores com diâmetros superiores à 50 cm em relação ao inventário florestal.

Em relação a parametrização e aplicação do classificador SVM, foram observados os seguintes resultados. O par de parâmetros otimizados, definidos por meio da validação cruzada,

Figura 20 – Intensidades de *keypoints* amostrados por diferentes funções de janelas de busca aplicadas ao algoritmo de máximos locais.



Fonte: Elaborada pelo autor.

para a etapa de ajuste dos parâmetros iniciais do classificador SVM foram dados por ($C = 1$, $\gamma = 0.5$), por ter produzido a maior acurácia média no processo. O *kernel* utilizado foi o radial.

Os testes de performance do classificador SVM denotaram bons níveis de precisão e acurácia para se filtrar as árvores suprimidas. Foram obtidas acurácia média de 79.67 ± 2.95 e precisão média de 82.42 ± 4.76 . Os resultados detalhados para cada um dos 20 testes realizados estão apresentados na Tabela 10.

O classificador SVM apresentou boa precisão para filtrar os *keypoints* que representam as árvores de pequeno porte ou suprimidas. O escaneamento por *LiDAR* denotou dificuldade para definir com precisão a altura de árvores de pequeno porte. Deste modo, a aplicação do classificador SVM foi importante para se definir em larga escala, quais *keypoints* dentre a nuvem de pontos 3d remetiam às árvores de interesse do manejo florestal. Como a modelagem do diâmetro foi realizada em função da altura *LiDAR*, o diâmetro foi estimado apenas para as árvores da classe B ($DBH \geq 33 \text{ cm}$).

Tabela 10 – Resultados referentes à avaliação de performance do classificador SVM - filtro de acordo com o experimento proposto.

Teste	VP	FN	FP	VN	Acurácia (%)	Precisão (%)
1	46	10	14	50	80.00	76.67
2	49	17	11	43	76.67	81.67
3	44	8	16	52	80.00	73.33
4	48	14	12	46	78.33	80.00
5	52	22	8	38	75.00	86.67
6	48	12	12	48	80.00	80.00
7	47	17	13	43	75.00	78.33
8	45	11	15	49	78.33	75.00
9	51	20	9	40	75.83	85.00
10	52	11	8	49	84.17	86.67
11	52	17	8	43	79.17	86.67
12	52	17	8	43	79.17	86.67
13	52	16	8	44	80.00	86.67
14	49	12	11	48	80.83	81.67
15	53	14	7	46	82.50	88.33
16	52	9	8	51	85.83	86.67
17	52	11	8	49	84.17	86.67
18	51	15	9	45	80.00	85.00
19	45	8	15	52	80.83	75.00
20	49	16	11	44	77.50	81.67
Média	49.45	13.85	10.55	46.15	79.67	82.42
Desvio padrão	2.86	3.92	2.86	3.92	2.95	4.76

Fonte: Elaborada pelo autor.

4.1 Modelagem estatística


A dispersão entre as alturas extraídas dos dados *LiDAR* e diâmetros medidos em campo, apresentada na Figura 21, denota elevada variabilidade entre características, que pode ser explicada pela diversidade das espécies que compõem a floresta amazônica. Foram avaliadas as transformações de dados descritas no modelos parabólico (A), reta (B), Stofel (C) e Curtis (D), e observou-se que a distribuição do diâmetro apresentou elevado espalhamento em relação à altura em todos os casos.

O modelo parabólico apresentou resultados estatisticamente superiores em relação aos demais modelos avaliados (Tabela 11), com menor valor de raiz do erro quadrático médio (*RMSE*), e maior coeficiente de determinação ajustado (R^2). Oliveira et al. (2014) obtiveram bons resultados em qualidade do ajuste ao aplicar o modelo parabólico para estimar o diâmetro de árvores em função da altura extraída dos dados *LiDAR*.

Na análise dos gráficos de dispersão dos resíduos (Figura 22) para os modelos avaliados, observou-se elevada variabilidade das variáveis dendrométricas, sendo que os maiores resíduos se relacionaram com espécies de grande porte. Verificou-se que houve melhor ajuste do modelo parabólico, por meio da identificação de tendências de heterocedasticidade dos demais modelos.

A modelagem do diâmetro em função da altura extraída dos dados *LiDAR* apresentou

Figura 21 – Dispersão das alturas extraídas dos dados *LiDAR* e diâmetros medidos em campo, dadas as tranformações de dados descritas nos modelos: - parabólico (A), - reta (B), - Stofel (C) e Curtis (D).



Fonte: Elaborada pelo autor.

Tabela 11 – Equações diamétricas ajustadas em função da altura e estatísticas do ajuste para os modelos: - parabólico (A), - reta (B), - Stofel (C) e Curtis (D).

Modelo	Equação ajustada	<i>RMSE</i>	R^2
A	$DBH = 56.0492986 - 1.4638431Ht_{LiDAR} + 0.0364938Ht_{LiDAR}^2 + \varepsilon$	10.5748	0.1940
B	$DBH = 22.4865591 + 0.7918496Ht_{LiDAR} + \varepsilon$	10.7998	0.1593
C	$Log(DBH) = 2.0992301 + 0.5113676 \times Log(Ht_{LiDAR}) + Log(\varepsilon)$	10.8910	0.1455
D	$DBH = 102.3955 - 187.9126/Log(Ht_{LiDAR}) + \varepsilon$	11.1589	0.1024

Fonte: Elaborada pelo autor.

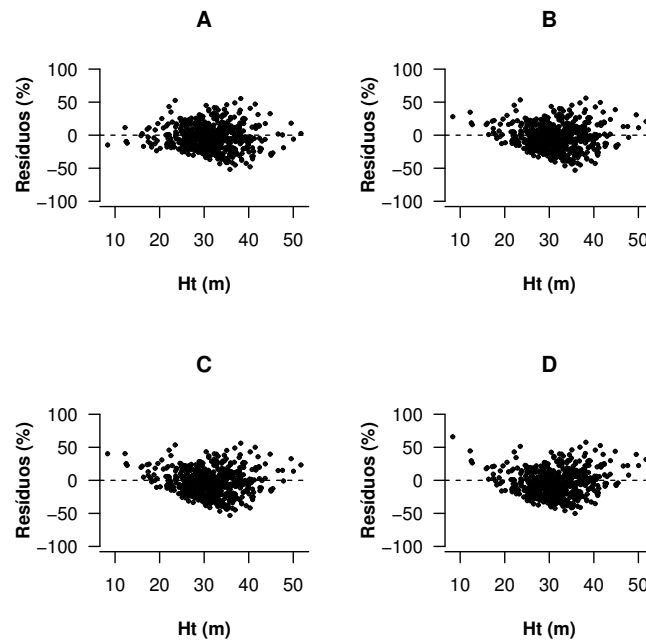
baixos níveis de ajustamento. Para validar a qualidade dos resultados obtidos, foi realizado um novo ajuste do modelo parabólico, porém, utilizando-se a altura medida no inventário como variável independente.

O modelo ajustado com os dados do inventário (Equação 21), remeteu aos seguintes resultados: $RMSE = 10.5947$ e $R^2 = 0.1910$. Esses resultados podem ser considerados similares aos obtidos pelo ajuste do modelo parabólico utilizando as alturas extraídas do *LiDAR*. O baixo nível de ajustamento, observado nos dois casos, pode ser explicado pela elevada diversidade biológica das espécies florestais da Amazônia.

$$DBH = 55.46435119 - 1.41338261Ht_{inv} + 0.03551306Ht_{inv}^2 + \varepsilon \quad (21)$$


Ao se comparar as dispersões dos erros percentuais entre os modelos $DBH \approx f(Ht_{LiDAR})$ e $DBH \approx f(Ht_{inv})$, percebe-se que as tendências da distribuições dos erros são similares entre os ajustes (Figura 23). A aplicação da correspondência de características com nível de incerteza dado por $idx \leq 0.75$ foi fundamental para que essa semelhança entre modelos fosse observada.

Figura 22 – Distribuição dos resíduos em percentagem do diâmetro em função da altura *LiDAR* para os modelos: - parabólico (A), - reta (B), - Stofel (C) e Curtis (D).



Fonte: Elaborada pelo autor.

Figura 23 – Comparação entre os resíduos percentuais em relação ao DBH em função das alturas extraídas do *LiDAR* e medidas no inventário.



Fonte: Elaborada pelo autor.

Na análise da Figura 23, constata-se que a tendência dos erros percentuais apresentou maior heterogeneidade dos resíduos em relação as maiores alturas. Essa tendência impactou diretamente na qualidade dos resultados, em termos da localização das árvores, pois as árvores

consideradas localizadas neste estudo foram dadas pelos *keypoints* que obtiveram $DBH \geq 50 \text{ cm}$ após aplicação deste modelo.


Após análise dos resultados, o modelo parabólico foi selecionado para estimar o diâmetro das árvores por meio da altura extraída dos dados *LiDAR*. Cabe ressaltar que, a escolha do modelo parabólico foi dada meramente pela análise estatística do ajuste. Estudos com enfoque na modelagem do diâmetro em função da altura das árvores, levando-se em consideração o realismo biológico do modelo, podem favorecer a diminuição de bias nas estimativas.

Grande parte do planejamento florestal é realizado utilizando-se o diâmetro das árvores como informação base, por se apresentar como uma variável fácil de se medir (SOUZA; SOARES, 2013). O *LiDAR* permite uma visão superior do dossel da floresta e não possibilita a extração direta do diâmetro das árvores. Estimativas do diâmetro em função da variável altura, extraída dos dados *LiDAR*, já foram obtidas com sucesso (OLIVEIRA et al., 2014). Entretanto, melhorias na modelagem do diâmetro em função de outras características extraídas dos dados *LiDAR*, podem trazer benefícios significativos para qualidade da localização remota de árvores.

4.2 Validação da localização de árvores

A Figura 24 foi utilizada para definição do valor do filtro (*idx*), em que pode-se avaliar o número de árvores localizadas em relação ao nível de incerteza aceito. Observou-se que quanto menor é o nível de incerteza, ao se definir a intensidade do filtro, maior é a precisão em relação à proximidade entre a árvore localizada e a coordenada da árvore referente no inventário, tal como, maior é a precisão entre as alturas e raios de copa médio. Ao se optar pela escolha de maiores valores de *idx*, mais árvores são localizadas, porém a precisão entre as características avaliadas diminui.

Figura 24 – Filtro (*idx*).



Fonte: Elaborada pelo autor.

Após execução do algoritmo de localização de árvores, com o filtro de incerteza definido por $idx \leq 7$, foram encontradas 162 (32,14%) árvores com diâmetro superior à 50 cm, nas regiões das parcelas definidas no inventário florestal. Eram esperadas ser encontradas 504 árvores. Na Tabela 12 são apresentados os resultados dos percentuais de localização remota das árvores na região das parcelas. Foram avaliadas variações dadas por diâmetros superiores à 45, 47,5 e 50 cm.

Tabela 12 – Resultados da localização remota de árvores em relação aos dados do inventário florestal.

Parcela	Inventário			LiDAR DBH > 45		LiDAR DBH > 47.5		LiDAR DBH > 50			Localizadas (%)
	N	\overline{Ht}	\overline{DBH}	N	(%)	N	(%)	N	\overline{Ht}	\overline{DBH}	
1	15	34.25	53.93	7	46.67	3	20	1	39.99	56.32	6.67
2	29	34.02	60.68	12	41.38	7	24.14	5	38.98	55.83	17.24
3	24	38.79	72.34	15	62.50	12	50	10	37.32	52.75	41.67
4	24	34.92	66.53	15	62.50	10	41.67	9	38.19	54.45	37.50
5	14	37.11	67.33	9	64.29	4	28.57	4	39.36	55.82	28.57
6	27	37.45	62.03	19	70.37	14	51.85	10	35.94	51.01	37.04
7	29	39.20	68.92	15	51.72	5	17.24	5	38.37	54.45	17.24
8	36	39.73	64.10	22	61.11	20	55.56	19	38.50	54.48	52.78
9	45	32.50	65.29	14	31.11	10	22.22	9	37.05	52.52	20
10	13	35.49	64.01	10	76.92	6	46.15	4	36.92	52.20	30.77
11	24	35.03	67.24	16	66.67	10	41.67	9	37.33	53.06	37.50
12	25	35.17	64.08	18	72	13	52	7	38.68	54.97	28
13	20	36.07	61.38	8	40	3	15	3	34.92	49.76	15
14	25	37.13	63.99	18	72	14	56	13	37.37	53.18	52
15	26	36.17	60.68	17	65.38	11	42.31	11	37.99	53.95	42.31
16	21	36.16	62.78	15	71.43	11	52.38	9	39.09	55.68	42.86
17	10	39.41	79	8	80	6	60	4	39.33	55.49	40
18	23	37.25	64.56	13	56.52	7	30.43	2	37.56	52.94	8.70
19	17	33.27	59.56	11	64.71	9	52.94	7	37.73	53.71	41.18
20	15	38.73	75.33	10	66.67	8	53.33	5	40.38	58.12	33.33
21	28	32.39	65.17	18	64.29	14	50	11	37.49	52.95	39.29
22	14	38.96	65.73	8	57.14	5	35.71	5	39.75	56.27	35.71
Totais	504	36.33	65.21	298	59.13	202	40.08	162	38.10	54.09	32.14

Fonte: Elaborada pelo autor.

Observou-se que o diâmetro foi subestimado pelo modelo estatístico ajustado com os dados de alturas extraídas do *LiDAR*. Foi possível visualizar uma diferença de aproximadamente 10 cm entre a média do diâmetro estimado e observado no inventário florestal. Tal fato pode ter ocorrido, pela dificuldade da modelagem da diversidade e abundância de espécies florestais existentes na floresta amazônica, conforme relatado por Figueiredo (1983), principalmente pela utilização de um modelo diamétrico generalista.

Além disso, a raiz do erro quadrático médio observada no ajuste do modelo A, apresentado na Tabela 11, denota que o erro na modelagem do diâmetro obteve variação na ordem de ± 10 cm. Desta forma, foram propostas análises utilizando-se folgas nos valores de diâmetro estimados, no intuito de se minimizar a influência dos erros de ajustamento do diâmetro na localização remota de árvores.


Ao se avaliar as árvores localizadas em um cenário que foi planejada uma folga de

2.5 cm têm-se: Para $DBH \geq 47.5$ cm foram localizadas 202 árvores (40.08%); Caso a folga for configurada para 5 cm, foi encontrado o seguinte resultado: Para $DBH \geq 45$ cm foram localizadas 298 árvores (59.13%).


Em algumas parcelas o percentual de árvores localizadas foi de aproximadamente 53%, como é o caso da parcela 8. Entretanto houveram casos com baixos percentuais de localização, como por exemplo a parcela 18, que apresentou aproximadamente 9% de localização de árvores em relação ao inventário florestal (Figura 25).

Figura 25 – Mapas da localização remota de árvores em relação ao inventário florestal, para árvores com diâmetro superiores à 50 cm, em uma parcela com baixo nível percentual de árvores localizadas (Parcela 18) e outra parcela com bom nível percentual de árvores localizadas (Parcela 8).

Parcela: 18



Parcela: 8




Fonte: Elaborada pelo autor.

Foi possível perceber que áreas com baixo espaçamento entre árvores com diâmetro superiores a 50 cm, resultaram em baixos níveis de localização. Na Figura 26, são apresentados os resultados de localização remota de árvores utilizando-se uma folga de 5 cm no diâmetro. Observou-se que os níveis de localização aumentaram, conforme esperado.


Ao se analisar os fatores que influenciaram os índices percentuais de localização remota de árvores, foi possível constatar que: - Os diâmetros foram subestimados pelo modelo proposto, principalmente para as árvores mais altas. Como esse foi o critério definido para localização, sugere-se novos estudos relacionados à modelagem do diâmetro em função de dados *LiDAR*, no intuito de que os níveis de localização remota de árvores sejam melhor definidos; - A amostragem relacionada à função de janela de busca define o número de *keypoints* avaliados, ou seja, janelas de busca menores tendem a remeter a um maior número de *keypoints* a serem avaliados. O dimensionamento das janelas de busca deve ser ponderada com cuidado, pois

Figura 26 – Mapas da localização remota de árvores em relação ao inventário florestal, para árvores com diâmetro superiores à 45 cm, em uma parcela com baixo nível percentual de árvores localizadas (Parcela 18) e outra parcela com bom nível percentual de árvores localizadas (Parcela 8).

Parcela: 18



Parcela: 8



Fonte: Elaborada pelo autor.

pode-se aumentar o número de falsos positivos, sendo que, a intensidade alta de *keypoints* pode superestimar o número de árvores numa área.

Outro fator que deve-se levar em consideração, neste tipo de planejamento, está relacionado ao estoque de madeira mantida por UPA. Por lei, exige-se que, sejam mantidas pelo menos 10% do número de árvores por espécie em cada UPA, ou no mínimo três árvores por espécie por 100 ha (Conselho Nacional do Meio Ambiente - CONAMA, 2009). Ou seja, se fosse realizada a exploração das árvores localizadas, restariam aproximadamente 70% das árvores que não foram encontradas pelo *LiDAR*. As árvores remanescentes tendem a garantir o estoque de forma indireta.

Ao se realizar a análise estrutural da floresta contemplando-se apenas as árvores localizadas pelo *LiDAR*, foram encontradas 71 espécies na região das parcelas do inventário florestal. Como no inventário florestal foram encontradas 96 espécies, as espécies localizadas perfazem 73,95% do total. Um resumo das espécies mais importantes localizadas de acordo com o índice IVI é apresentada na Tabela 13.

Dentre as 71 espécies localizadas 27 (38.03%) foram consideradas espécies madeiras de interesse comercial, de acordo com o Serviço Florestal Brasileiro (SNIF, 2019).

As espécies que não foram localizadas são apresentadas na Tabela 14, de forma ordenada de acordo com o IVI. A primeira espécie não encontrada é dada pela *Caryocar villosum*. A espécie é comum na Amazônia central e é representada por indivíduos de nome popular piquiá.

Tabela 13 – Lista em ordem decrescente das 15 espécies com maior valor de IVI localizadas pelo LiDAR

Espécie	FA	FR	DA	DR	DoA	DoR	IVC	IVI	Comercial
<i>Pouteria gongrijpii</i>	40.91	5.52	0.77	8.50	0.16	8.01	8.25	7.34	N
<i>Manilkara huberi</i>	36.36	4.91	0.45	5.00	0.10	5.20	5.10	5.04	S
<i>Manilkara bidentata</i>	31.82	4.29	0.45	5.00	0.10	5.02	5.01	4.77	S
<i>Eschweilera coriacea</i>	31.82	4.29	0.36	4.00	0.08	4.18	4.09	4.16	S
<i>Tachigali myrmecophila</i>	31.82	4.29	0.32	3.50	0.06	3.24	3.37	3.68	N*
<i>Tetragastris altissima</i>	22.73	3.07	0.36	4.00	0.08	3.91	3.95	3.66	N
<i>Pouteria oppositifolia</i>	27.27	3.68	0.27	3.00	0.06	3.00	3.00	3.23	N
<i>Tetragastris panamensis</i>	18.18	2.45	0.32	3.50	0.06	3.16	3.33	3.04	N
<i>Pouteria sp.</i>	22.73	3.07	0.27	3.00	0.06	2.82	2.91	2.96	N
<i>Lecythis lurida</i>	18.18	2.45	0.27	3.00	0.06	2.94	2.97	2.80	S
<i>Eschweilera ovata</i>	18.18	2.45	0.23	2.50	0.05	2.41	2.46	2.46	N
<i>Astronium graveolens</i>	18.18	2.45	0.18	2.00	0.05	2.65	2.33	2.37	S
<i>Eschweilera amazonica</i>	9.09	1.23	0.23	2.50	0.06	2.82	2.66	2.18	N
<i>Protium hebetatum</i>	13.64	1.84	0.18	2.00	0.05	2.59	2.30	2.15	S
<i>Pouteria guianensis</i>	18.18	2.45	0.18	2.00	0.04	1.84	1.92	2.10	N

Fonte: Elaborada pelo autor.

As árvores dessa espécie têm altura podendo atingir até 50 m e diâmetro de até 2.5 m. Esses indivíduos podem não ter sido localizados remotamente, devido aos problemas relacionados à estimativa do diâmetro de árvores de maior porte, principalmente pelo modelo generalista não ter conseguido estimar as especificidades desta espécie. Outro fator que pode ter afetado a localização dessa espécie, se dá pela baixa frequência observada, que pode denotar que essa espécie tem baixa ocorrência na área.

A segunda espécie da lista das não encontradas é a *Licania guianenses*. Essa espécie está localizada na posição 38 em valor de importância no inventário florestal. Ou seja, as espécies não localizadas obtiveram baixo IVI, o que implica menor relevância entre as demais. A frequência relativa observada dessas espécies é baixa, o que pode denotar que com a baixa amostragem de localização de árvores, aproximadamente 30 % em relação aos dados das parcelas do inventário florestal, tenham feito com que essas poucas árvores destas espécies não fossem contempladas na análise estrutural.

Ao se verificar a relação entre as 15 primeiras espécies classificadas pelo IVI, do inventário florestal e das árvores localizadas, pode-se observar na Tabela 15, que apenas 3 espécies não foram classificadas entre as 15 primeiras localizadas pelo LiDAR. Ou seja, mesmo com uma amostragem aproximadamente 70% menor do que a base de dados do inventário a estrutura da floresta ainda foi mantida.

4.3 Dimensionamento das Unidades de Produção Anual

De posse do modelo digital de superfície da área em estudo, foi aplicado o algoritmo de máximo local configurado com a função de janela de busca dada por: $janela = 0.6 + 0.03 * H$.

* Espécie não catalogada pelo Serviço Florestal Brasileiro de acordo com a classificação de espécie madeireira de interesse comercial.

Tabela 14 – Não encontradas

Espécie	FA	FR	DA	DR	DoA	DoR	IVC	IVI	Comercial
<i>Caryocar villosum</i>	13.64	0.81	0.18	0.79	0.22	2.68	1.74	1.43	S
<i>Licania guianensis</i>	18.18	1.08	0.23	0.99	0.05	0.66	0.83	0.91	N
<i>Eperua bijuga</i>	18.18	1.08	0.18	0.79	0.04	0.55	0.67	0.81	N
<i>Stryphnodendron paniculatum</i>	13.64	0.81	0.14	0.59	0.07	0.86	0.72	0.75	N
<i>Mezilaurus itauba</i>	9.09	0.54	0.09	0.39	0.05	0.61	0.50	0.52	S
<i>Stryphnodendron pulcherrimum</i>	9.09	0.54	0.09	0.39	0.03	0.38	0.38	0.44	N
<i>Lecythis idatimon</i>	9.09	0.54	0.09	0.39	0.03	0.37	0.38	0.43	N*
<i>Ormosia coccinea</i>	9.09	0.54	0.09	0.39	0.03	0.35	0.37	0.43	N
<i>Hymenaea parvifolia</i>	9.09	0.54	0.09	0.39	0.03	0.32	0.36	0.42	S
<i>Abarema jupunba</i>	9.09	0.54	0.09	0.39	0.02	0.27	0.33	0.40	N
<i>Abarema cochleata</i>	9.09	0.54	0.09	0.39	0.02	0.25	0.32	0.39	N
<i>Parkia gigantocarpa</i>	4.55	0.27	0.05	0.20	0.03	0.40	0.30	0.29	N*
<i>Qualea paraensis</i>	4.55	0.27	0.05	0.20	0.03	0.38	0.29	0.28	S
<i>Parkia nitida</i>	4.55	0.27	0.05	0.20	0.03	0.34	0.27	0.27	N*
<i>Capirona decorticans</i>	4.55	0.27	0.05	0.20	0.02	0.30	0.25	0.25	N
<i>Lacunaria jenmanii</i>	4.55	0.27	0.05	0.20	0.02	0.30	0.25	0.25	N
<i>Inga marginata</i>	4.55	0.27	0.05	0.20	0.02	0.28	0.24	0.25	N
<i>Couepia robusta</i>	4.55	0.27	0.05	0.20	0.02	0.19	0.19	0.22	N
<i>Cordia scabrifolia</i>	4.55	0.27	0.05	0.20	0.01	0.17	0.18	0.21	N*
<i>Vatairea guianensis</i>	4.55	0.27	0.05	0.20	0.01	0.16	0.18	0.21	N
<i>Vismia floribunda</i>	4.55	0.27	0.05	0.20	0.01	0.15	0.17	0.21	N
<i>Inga sp.</i>	4.55	0.27	0.05	0.20	0.01	0.14	0.17	0.20	N
<i>Hymenolobium heterocarpum</i>	4.55	0.27	0.05	0.20	0.01	0.13	0.17	0.20	S
<i>Ormosia nobilis</i>	4.55	0.27	0.05	0.20	0.01	0.12	0.16	0.20	N
<i>Diploptropis sp.</i>	4.55	0.27	0.05	0.20	0.01	0.12	0.16	0.19	N*

Fonte: Elaborada pelo autor.

Tabela 15 – Não encontradas dentre as primeiras 15

Espécie	FA	FR	DA	DR	DoA	DoR	IVC	IVI	Comercial
<i>Dinizia excelsa</i>	22.73	1.35	0.23	0.99	0.38	4.63	2.81	2.32	S
<i>Pouteria hispida</i>	40.91	2.43	0.55	2.37	0.14	1.73	2.05	2.18	N
<i>Couratari stellata</i>	36.36	2.16	0.45	1.97	0.12	1.49	1.73	1.88	S

Fonte: Elaborada pelo autor.

Deste modo, foram obtidos 43741 *keypoints* perfazendo uma intensidade de 36.03 *kps/ha*.

O classificador SVM foi novamente treinado, utilizando-se a base de dados de correspondência de características com nível de incerteza ≤ 0.75 , configurado com o mesmo par de parâmetros obtido na validação cruzada ($C = 1$, $\gamma = 0.5$). O novo classificador treinado, foi aplicado como filtro em todos os *keypoints* amostrados no passo anterior. O classificador SVM removeu 4462 (10.20%) de 43741 *keypoints* avaliados.


Foi então aplicado o modelo diamétrico (Modelo A), apresentado na Tabela 11, para estimar o diâmetro das árvores da classe B ($DBH \geq 33$), representadas por 39279 *keypoints*. Foram então selecionados os *keypoints* com $DBH \geq 47.5$, utilizando-se uma folga de 2.5 cm no diâmetro. Desta forma, restaram 9299 *keypoints* na região de estudo, perfazendo uma intensidade

* Espécie não catalogada pelo Serviço Florestal Brasileiro de acordo com a classificação de espécie madeireira de interesse comercial.

de 7.66 kps/ha.

O volume foi estimado para os 9299 *keypoints*, que representam as árvores com $DBH \geq 47.5$. Para tanto, a altura extraída do dados *LiDAR* foi ajustada por meio da função: $Ht_{ajustada} = 0.2069269 + 1.0024616Ht_{LiDAR} + \varepsilon$. A precisão observada no ajuste foi dada por: $RMSE = 0.1965$ e $R^2 = 0.9989$. A dispersão dos erros é apresentada na Figura 27.

Figura 27 – Resíduos percentuais da altura ajustada em relação à altura extraída do *LiDAR*.



Fonte: Elaborada pelo autor.

Na análise da Figura 27, constata-se que a precisão da altura ajustada é maior para as árvores mais altas. Este resultado é relevante, pois os *keypoints* que obtiveram a altura ajustada possuem características de árvores dominantes.

Na sequência, foi estimado o volume das árvores por meio da aplicação da Equação 19, de acordo com a estratificação diamétrica proposta por Cysneiros et al. (2017). Nesta estimativa de volume foi utilizada a altura ajustada no passo anterior.

Com a proposta de se mapear as unidades de produção anual, foi realizado o planejamento do percentual de exploração baseado nas taxas definidas neste estudo. Foi proposta a utilização de 2.5 cm de folga no diâmetro e foi aceito um nível de incerteza de $idx \leq 7$. Desta forma, o percentual de localização obtido foi de 40,08%. A taxa de aproveitamento da madeira foi definida de forma empírica, conforme apresentado na Tabela 16.

O planejamento do dimensionamento das unidades de produção anual foi realizado utilizando-se a taxa percentual de exploração dada por 14.48% do censo das árvores na área.

Após a definição do percentual de exploração, foi possível avaliar os resultados referentes ao experimento para escolha do número de unidades de produção anual (Tabela 17). A taxa percentual de exploração foi utilizada neste experimento para se obter informações referentes ao potencial madeireiro. Para cada teste relacionado à divisão da área em k UPAs, foi descrito o potencial madeireiro por meio do número médio de árvores por hectare e pelo volume médio dado em m^3/ha .

Tabela 16 – Taxas utilizadas no planejamento do dimensionamento de UPAs.

	Percentual (%)
Censo das árvores na área	100
Taxa de localizadas em campo	40.08
Taxa de potencial madeireiro	38.03
Taxa de aproveitamento	95
Taxa a utilizada no planejamento	14.48

Fonte: Elaborada pelo autor.

Tabela 17 – Análise para definição do número de UPAs.

<i>k</i>	Média por clusters					Potencial Madeireiro	
	\overline{nArv}	\overline{nArv}/ha	$\overline{vol_{total}}$	$\overline{m^3}/ha$	$\overline{Área} (ha)$	\overline{nArv}/ha	$\overline{m^3}/ha$
2	4641.00	7.77	27710.77	46.35	596.56	2.81	16.74
3	3094.00	7.87	18473.84	47.10	394.67	2.84	17.02
4	2320.50	7.91	13855.38	47.26	295.68	2.86	17.08
5	1856.40	7.89	11084.31	47.05	235.70	2.85	17.00
6	1547.00	8.01	9236.92	47.91	196.35	2.89	17.31
7	1326.00	8.10	7917.36	48.53	167.13	2.93	17.53
8	1160.25	8.10	6927.69	48.42	145.57	2.93	17.49
9	1031.33	8.13	6157.95	48.59	129.04	2.94	17.55
10	928.20	8.16	5542.15	48.79	116.24	2.95	17.63
11	843.82	8.28	5038.32	49.56	105.31	2.99	17.91
12	773.50	8.27	4618.46	49.50	95.70	2.99	17.88
13	714.00	8.32	4263.19	49.83	88.15	3.01	18.00
14	663.00	8.33	3958.68	50.02	82.04	3.01	18.07
15	618.80	8.45	3694.77	50.70	76.25	3.05	18.32
16	580.12	8.42	3463.85	50.45	71.16	3.04	18.23
17	546.00	8.45	3260.09	50.64	67.10	3.05	18.30
18	515.67	8.51	3078.97	50.97	62.81	3.07	18.41
19	488.53	8.51	2916.92	50.89	59.14	3.07	18.39
20	464.10	8.58	2771.08	51.36	56.10	3.10	18.55

Fonte: Elaborada pelo autor.


As informações apresentadas na Tabela 17, foram utilizadas para planejar o número de unidades de produção anual que podem vir a ser definidas na área. Essas informações podem ser consideradas úteis para embasar a composição de mapas pré-exploratórios do plano de manejo sustentável.

De acordo com Reis et al. (2013), uma unidade de trabalho (UT) define os limites de uma área em que será realizada a exploração florestal. De maneira geral, as UTs são dimensionadas em áreas de 100 *ha*. As unidades de produção anual tendem a ser baseadas na delimitação das unidades de trabalho. Desta forma, pode-se escolher o valor de $k = 11$, e assim, a área de estudo seria dividida em 11 unidades de produção anual, com tamanho médio de 105 *ha*, podendo-se explorar um potencial madeireiro médio de aproximadamente 3 árvores por hectare.

Foi proposto um exemplo prático, dado pelo planejamento da divisão da área de

estudo em 5 unidades de produção anual. Espera-se que área média de cada UPA tenha a dimensão aproximada de 235 *ha*, podendo-se explorar um volume médio de 17 m^3/ha , denotado por aproximadamente 2.85 árvores por hectare, conforme apresentado na Tabela 17. O mapa do dimensionamento das 5 UPAs é apresentado na Figura 28.

Figura 28 – Mapa do dimensionamento de 5 unidades de produção anual - Exemplo prático.



Fonte: Elaborada pelo autor.

Os resultados obtidos do detalhamento das informações das 5 unidades de produção anual, em referência ao exemplo prático, são apresentados na Tabela 18. Foi possível validar as informações esperadas, em relação à área média e discriminação do potencial madeireiro. A área média observada entre UPAs foi de 235.43 *ha*. O potencial madeireiro observado no exemplo, foi dado pela média de 2.85 árvores por hectare entre UPAs, que remetem à um volume médio de 17.02 m^3/ha .

Para se realizar o equilíbrio das informações de área ou potencial madeireiro discriminadas por UPA, pode-se utilizar otimização matemática ou heurística com enfoque em regulação florestal. De acordo com Leite et al. (2016), o dimensionamento das UPAs pode ser otimizado conforme diferentes objetivos da regulação florestal, como por exemplo, pela equivalência do volume de corte entre áreas, pela receita a ser obtida ou pela divisão do número

Tabela 18 – Informações detalhadas das 5 unidades de produção anual - Exemplo prático.

UPA	Total Árvores _{DBH>50}						Potencial Madeireiro	
	Área (ha)	n	\overline{Ht}	\overline{DBH}	nArv/ha	m ³ /ha	nArv/ha	m ³ /ha
1	218.44	1782	37.12	55.86	8.16	48.33	2.95	17.46
2	229.16	1704	37.17	55.81	7.44	43.97	2.69	15.89
3	261.28	2096	37.57	56.54	8.02	49.63	2.90	17.93
4	239.46	1614	36.55	55.46	6.74	38.97	2.44	14.08
5	228.80	2086	37.49	56.24	9.12	54.59	3.29	19.72
Média	235.43						2.85	17.02

Fonte: Elaborada pelo autor.

de árvores em classes. Portanto, as informações obtidas por meio da metodologia proposta neste trabalho, podem ser úteis para o planejamento da regulação florestal.

5 CONCLUSÕES

A metodologia proposta para processar dados obtidos do escaneamento por laser aerotransportado, se apresentou como ferramenta poderosa para mapear o potencial madeireiro em áreas de floresta amazônica.

Observou-se vantagens em relação ao planejamento da exploração florestal tradicional, principalmente pela obtenção remota da maioria das informações utilizadas no processo, possibilitando o mapeamento do potencial madeireiro em áreas extensas, em florestas densas ou de difícil acesso.

O lançamento e avaliação de parcelas em campo, ainda são processos requeridos pela metodologia proposta. As informações obtidas do inventário florestal foram utilizadas na modelagem do diâmetro das árvores, planejamento dos percentuais de exploração e na avaliação da performance do método. Entretanto, a utilização dessas informações tem enfoque diferente do planejamento da exploração florestal tradicional, em que são realizados censos. As idas a campo passam ter enfoque na validação das informações previamente planejadas, e podem ser realizadas em conjunto com as etapas de exploração. Desta forma, pode-se obter economias de recursos financeiros e humanos ao se aplicar a metodologia proposta neste trabalho.

De maneira geral, foram localizadas remotamente 32% das árvores com diâmetro superior à 50 cm. Se forem consideradas folgas no processo, o nível de localização remota de árvores atingiu aproximadamente 60% de acerto. Ao se analisar as árvores localizadas remotamente, pode-se considerar que a estrutura da floresta encontrada foi similar à estrutura apresentada no inventário florestal.

As informações referentes ao mapeamento do potencial madeireiro, obtidas por meio da aplicação da metodologia proposta neste trabalho, podem ser relevantes para o dimensionamento das unidades de produção anual. Consequentemente, podem favorecer o planejamento de UPAs com enfoque na regulação florestal.

CONSIDERAÇÕES FINAIS

Os estudos desenvolvidos nos dois capítulos da tese demonstram a viabilidade da aplicação da tecnologia *LiDAR* em florestas tropicais, que possibilita realizar o mapeamento do potencial madeireiro para fins de facilitação e otimização do planejamento da exploração de manejos florestais que empregam técnicas de precisão.

Técnicas do sensoriamento remoto em conjunto com o manejo florestal de precisão podem vir a substituir processos referentes ao planejamento da exploração florestal sustentável, como por exemplo o inventário florestal 100%. Com a aplicação do mapeamento do potencial madeireiro proposto neste estudo, o planejamento passa a ter enfoque apenas nos indivíduos de interesse madeireiro, diferentemente do censo. Se aplicada em larga escala pode trazer economias de recursos financeiros e humanos, por meio de práticas menos invasivas, e podendo favorecer o conhecimento prévio e generalista da área destinada à exploração florestal.

O índice de incerteza proposto se apresentou versátil e crucial para realização do mapeamento do potencial madeireiro em áreas de floresta amazônica. Com sua utilização foi possível atingir maiores níveis de precisão na modelagem do diâmetro das árvores. Também foi utilizado com sucesso como parâmetro de validação da localização das árvores.

Cabe ressaltar que a fórmula proposta para esse índice de incerteza não é definitiva. Ela pode ser alterada de acordo com as características que estiverem disponíveis em ambas fontes de dados.

Uma questão que vem sendo estudada é a definição ótima das funções de janela de busca utilizadas junto ao algoritmo LMF. Este estudo traz um enfoque diferente para a janela de busca, sendo que o objetivo é encontrar os pontos de interesse que após filtragem remeterão às árvores localizadas. Portanto, otimizações das janelas de busca com esse enfoque podem vir a melhorar o nível de localização de árvores de interesse do manejo florestal.

A extração da característica raio de copa neste estudo, foi proposta conforme a forma apresentada no inventário florestal. A avaliação de outras técnicas para extração do raio de copa dos dados *LiDAR* podem trazer melhores níveis de precisão na definição da incerteza. Estudos específicos para obtenção do raio de copa, nas direções cardinais, podem denotar um parâmetro interessante para o manejo florestal de precisão, principalmente para regiões de florestas densas em que os métodos de definição do diâmetro de copa tendem a apresentar dificuldades em prover bons resultados.

Acredita-se que o mapeamento remoto dos indivíduos de interesse do manejo florestal de precisão pode fornecer informações consistentes para a otimização do dimensionamento de UPAs. O uso dessa abordagem pode prover vantagens estratégicas, ao possibilitar o planejamento da regulação florestal e definição das unidades de produção antes mesmo de ir a campo. Portanto, o dimensionamento e localização espacial das unidades de produção anual podem ser realizados com enfoque em diferentes objetivos, sejam eles do ponto de vista de otimização matemática ou heurística.

As técnicas de manejo de precisão em florestas tropicais encontram-se em constante desenvolvimento. Espera-se que os resultados deste trabalho contribuam de forma prática, com a

evolução do manejo florestal de precisão.

O código contemplando todas implementações utilizadas neste estudo está disponível para acesso na íntegra no *GitHub*².

² <<https://github.com/eduardopelli/tese.git>>

REFERÊNCIAS

- ANGUITA, D.; RIDELLA, S.; RIVIECCIO, F. K-fold generalization capability assessment for support vector classifiers. In: *Proceedings. 2005 IEEE International Joint Conference on Neural Networks, 2005*. [S.l.: s.n.], 2005. v. 2, p. 885–858. Citado na página 68.
- ARTHUR, D.; VASSILVITSKII, S. K-means++: The advantages of careful seeding. In: *Proceedings of the Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms*. Philadelphia, PA, USA: Society for Industrial and Applied Mathematics, 2007. (SODA '07), p. 1027–1035. ISBN 978-0-898716-24-5. Disponível em: <<http://dl.acm.org/citation.cfm?id=1283383.1283494>>. Citado na página 72.
- CANNY, J. A computational approach to edge detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 8, n. 6, 1986. Citado na página 53.
- COHEN, J. *Statistical Power analysis for the behavioral sciences*. 2. ed. [S.l.]: NJ: Erlbaum, 1988. Citado 2 vezes nas páginas 43 e 46.
- Conselho Nacional do Meio Ambiente - CONAMA. Resolução nº 406, de 02 de fevereiro de 2009. *Publicado no DOU nº 26, de 06/02/2009*, Brasil. Brasília, DF, n. 26, p. 100, fev 2009. Citado 3 vezes nas páginas 22, 61 e 80.
- CURRAN, P. J.; ATKINSON, P. M. Geostatistics and remote sensing. *Progress in Physical Geography*, v. 22, n. 1, p. 61–78, 1998. Citado 2 vezes nas páginas 40 e 52.
- CYSNEIROS, V. C. et al. Modelos genéricos e específicos para estimativa do volume comercial em uma floresta sob concessão na amazônia. *Scientia Forestalis*, v. 45, n. 114, p. 295–304, 2017. Citado 2 vezes nas páginas 70 e 83.
- DAUGMAN, J. G. Uncertainty relation for resolution in space, spatial frequency, and orientation optimized by two-dimensional visual cortical filters. *Optical Society of America*, v. 2, p. 1160–1169, 1985. Citado na página 53.
- DIVIS, D. A. Sa: Going the way of the dinosaur. *GPS World*, p. 16–19, 2000. Citado 2 vezes nas páginas 23 e 39.
- DUDA, R. O.; HART, P. E.; STORK, D. G. *Pattern Classification*. [S.l.]: Wiley-Interscience Publication, 2001. Citado 2 vezes nas páginas 65 e 72.
- FACELI, K. et al. *Inteligência artificial: Uma abordagem de aprendizado de máquina*. Rio de Janeiro: LTC, 2011. Citado na página 39.
- FERREIRA, D. R. *Validação do modelo digital de exploração florestal (MODEFLORA) na fase pré-exploratória em florestas manejadas no Amazonas*. Dissertação (Mestrado) — Universidade Federal do Amazonas - Faculdade de Ciências Agrárias, Manaus, 2012. Citado 2 vezes nas páginas 21 e 33.
- FIGUEIREDO, A. F. *Estudos de modelos matemáticos para estimar o volume por unidade de área em uma floresta tropical úmida na Amazônia brasileira*. 176 p. Dissertação (Mestrado) — Universidade Federal do Paraná, Curitiba, 1983. Citado na página 78.
- FIGUEIREDO, E. O.; BRAZ, E. M. noz; D'OLIVEIRA, M. V. N. *Manejo de precisão em florestas tropicais: modelo digital de exploração florestal*. Rio Branco: Embrapa Acre, 2007. Citado 2 vezes nas páginas 21 e 33.

FORSYTH, D. A.; PONCE, J. *Computer Vision, A Modern Approach*. [S.l.]: Prentice Hall, 2003. ISBN 0-12-379777-2. Citado 2 vezes nas páginas 34 e 65.

GEOG 481 Topographic Mapping with Lidar. PennState - College of Earth and Mineral Sciences: Departament of Geography, 2017. Disponível em: <www.e-education.psu.edu/geog481/11_p3.html>. Citado na página 22.

GIONGO, M. et al. Lidar: princípios e aplicações florestais. *Pesquisa Florestal Brasileira*, Embrapa Florestas, v. 30, n. 63, p. 231–244, Oct 2010. ISSN 1983-2605. Disponível em: <<http://dx.doi.org/10.4336/2010.pfb.30.63.231>>. Citado na página 22.

GÖRGENS, E. B. *LiDAR technology applied to vegetation quantification and qualification*. Tese (Doutorado) — University of São Paulo “Luiz de Queiroz” College of Agriculture, Piracicaba, 2014. Citado 2 vezes nas páginas 22 e 33.

GÖRGENS, E. B. et al. Identificação de árvores individuais a partir de levantamentos laser aerotransportado por meio de janela inversa. *Revista Cerne*, v. 21, n. 1, p. 91–96, 2015. ISSN 0104-7760. Citado na página 45.

GÖRGENS, E. B. et al. Characterization of brazilian forest types utilizing canopy height profiles derived from airborne laser scanning. *Applied Vegetation Science*, v. 19, n. 3, p. 518–527, 2016. Citado 2 vezes nas páginas 34 e 62.

HARTIGAN, J. A.; WONG, M. A. Algorithm as 136: A k-means clustering algorithm. *Applied Statistics*, v. 28, p. 100–108, 1979. Citado na página 72.

HUDAK, A. T. et al. Nearest neighbor imputation of species-level, plot-scale forest structure attributes from lidar data. *Remote Sensing of Environment*, Amsterdam, v. 112, n. 5, p. 2232–2245, 2008. Citado 2 vezes nas páginas 22 e 33.

HUISING, E. J.; PEREIRA, L. M. G. Errors and accuracy estimates of laser data acquired by various laser scanning systems for topographic applications. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 53, n. 5, p. 245–261, 1998. Citado na página 41.

HUNTER, M. O. et al. Tree height and tropical forest biomass estimation. *Biogeosciences*, v. 10, p. 8385–8399, 2013. Citado na página 35.

HYYPÄÄ, J. et al. Advances in forest inventory using airborne laser scanning. *Remote Sensing*, Basel, v. 4, n. 5, p. 1190–1207, 2012. Citado 2 vezes nas páginas 22 e 33.

INPE. *Instituto Nacional de Pesquisas Espaciais*. 2019. Disponível em: <<http://www.inpe.br>>. Citado na página 21.

JENSEN, J. R. *Remote Sensing of the Environment: An Earth Resource Perspective*. 2nd edition. ed. [S.l.]: Prentice Hall, 2007. Citado na página 22.

KE, Y.; QUACKENBUSH, L. J. A review of methods for automatic individual tree-crown detection and delineation from passive remote sensing. *International Journal of Remote Sensing*, v. 32, n. 17, p. 4725–4747, 2011. Citado 2 vezes nas páginas 23 e 34.

KEEFE, K. et al. Enrichment planting as a silvicultural option in the eastern amazon: Case study of fazenda cauaxi. *Forest Ecology and Management*, v. 258, n. 9, p. 1950–1959, 2009. Citado 2 vezes nas páginas 34 e 62.

- KOHAVI, R.; PROVOST, F. Glossary of terms. *Machine Learning*, v. 30, n. 2-3, p. 271–274, 1998. Citado na página 68.
- LARSEN, M. Finding an optimal match window for spruce top detection based on an optical tree model. In: *International Forum on Automated Interpretation of High Spatial Resolution Digital Imagery for Forestry*. Victoria, BC, Canada: [s.n.], 1999. p. 55–63. Citado na página 72.
- LEITE, C. C. C. et al. Um método heurístico para otimizar a formação de unidades de produção anual no manejo de florestas nativas na amazônia. In: *IX Simpósio Brasileiro de Pós-Graduação em Ciências Florestais*. Guarapari - ES: [s.n.], 2016. Citado 2 vezes nas páginas 61 e 85.
- LEMES, P. et al. Refinando dados espaciais para a conservação da biodiversidade. *Natureza & Conservação*, v. 9, n. 2, p. 240–243, 2011. Citado na página 23.
- LEUSCHNER, W. *Introduction to Forest Resource Management*. Krieger Publishing Company, 1984. ISBN 9780894646416. Disponível em: <<https://books.google.com.br/books?id=7QEKAQAAMAAJ>>. Citado na página 61.
- MACEDO, R. C. *Prognose madeireira de plantio clonal de Eucalyptus spp. Através de dados derivados de LiDAR aerotransportado*. 133 p. Dissertação (Dissertação (Mestrado em Sensoriamento Remoto)) — Instituto Nacional de Pesquisas Espaciais - Ministério da Ciência e Tecnologia, São José dos Campos, 2009. Citado na página 22.
- MALTAMO, M. et al. Estimation of timber volume and stem density based on scanning laser altimetry and expected tree size distribution functions. *Remote Sensing of Environment*, v. 90, p. 319–330, 2004. Citado 2 vezes nas páginas 22 e 71.
- MCGAUGHEY, R. *FUSION/LDV: Software for LIDAR Data Analysis and Visualization*. Pacific Northwest Research Station, 2016. Citado na página 36.
- NÆSSET, E. Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data. remote sensing of environment. *Remote Sensing of Environment*, v. 80, n. 1, p. 88–99, 2002. Citado 2 vezes nas páginas 22 e 33.
- NÆSSET, E. Practical large-scale forest stand inventory using a small-footprint airborne scanning laser. *Scandinavian Journal for Research*, v. 19, p. 164–179, 2004. ISSN 0282-7581. Citado na página 33.
- NUTTO, L. Manejo do crescimento diamétrico de araucaria angustifolia (bert.) o. ktze. baseado na árvore individual. *Ciência Florestal*, v. 11, n. 2, p. 9–25, 2001. Citado na página 22.
- OLIVEIRA, L. T. de et al. Determinação do volume de madeira em povoamento de eucalipto por escâner a laser aerotransportado. *Pesquisa Agropecuária Brasileira*, v. 49, n. 9, p. 692–700, 2014. Citado 6 vezes nas páginas 22, 50, 61, 69, 75 e 77.
- PELLI, E.; GÖRGENS, E. B. Correspondência de características entre dados do inventário florestal e lidar para uma área de floresta amazônica. *Universidade Federal dos Vales do Jequitinhonha e Mucuri - UFVJM*, No prelo, 2019. Citado 3 vezes nas páginas 62, 66 e 67.
- PINAGÉ, E. R. et al. *Avaliação temporal dos efeitos da exploração madeireira usando dados Lidar*. João Pessoa-PB, 2015. Citado 4 vezes nas páginas 34, 35, 63 e 64.
- PIRES, J. M. *Uso do LiDAR (Light Detection and Ranging) para estimação da altura de árvores em povoamentos de eucalipto*. Tese (Doutorado) — Universidade Federal de Viçosa - UFV, 2005. Citado 3 vezes nas páginas 22, 49 e 71.

POPESCU, S. C.; WYNNE, R. H. Seeing the trees in the forest: Using lidar and multispectral data fusion with local filtering and variable window size for estimating tree height. *Photogrammetric Engineering & Remote Sensing*, v. 70, n. 5, p. 589–604, 2004. Citado 9 vezes nas páginas 11, 22, 23, 37, 41, 45, 47, 65 e 72.

POPESCU, S. C.; WYNNE, R. H.; NELSON, R. F. Estimating plot-level tree heights with lidar: local filtering with a canopy-height based variable window size. *Computers and Electronics in Agriculture*, Amsterdam, v. 37, n. 1/3, p. 71–95, Dec 2002. Citado 4 vezes nas páginas 21, 33, 46 e 61.

REIS, C. T. M. D. dos; RIBEIRO, O. de S. *Amazônia: responsabilidade sobre o mundo*. 2014. Citado na página 21.

REIS, S. L. et al. *Técnicas Pré-Exploratórias para o Planejamento da Exploração de Impacto Reduzido no Manejo Florestal Comunitário e Familiar*. Manual técnico 3. Belém, 2013. Citado 4 vezes nas páginas 21, 61, 71 e 84.

RIBAS, R. P. *Individualização de árvores em ambiente Florestal Nativo utilizando métodos de segmentação em modelos digitais produzidos a partir da tecnologia LiDAR*. Dissertação (Mestrado) — Universidade Federal de Minas Gerais - Instituto de Geociências, Belo Horizonte, 2011. Citado na página 22.

SANTO, H. A. E.; DANIEL, F. Calcular e apresentar tamanhos do efeito em trabalhos científicos (1): As limitações do $p < 0,05$ na análise de diferenças de médias de dois grupos. *Revista Portuguesa de Investigação Comportamental e Social*, v. 1, p. 3–16, 2015. Citado na página 43.

SNIF. *Portal do Sistema Nacional de Informações Florestais*. 2019. Disponível em: <<http://snif.florestal.gov.br/pt-br/especies-florestais>>. Citado 4 vezes nas páginas 21, 61, 63 e 80.

SOUZA, A. L. de; SOARES, C. P. B. *Florestas nativas : estrutura, dinâmica e manejo*. Viçosa, MG: Editora UFV, 2013. Citado 2 vezes nas páginas 61 e 77.

SZELISKI, R. *Computer vision algorithms and applications*. London; New York: Springer, 2011. Disponível em: <<http://dx.doi.org/10.1007/978-1-84882-935-0>>. Citado 3 vezes nas páginas 34, 36 e 65.

TIEDE, D.; HOCHLEITNER, G.; BLASCHKE, T. A full gis-based workflow for tree identification and tree crown delineation using laser scanning. In: *ISPRS CMRT: International Society for Photogrammetry and Remote Sensing*. Vienna, Austria: [s.n.], 2005. XXXVI, p. 9–14. Citado 9 vezes nas páginas 11, 21, 22, 23, 33, 45, 46, 47 e 61.

USSYSHKIN, R. V.; SMITH, B.; FIDERA, A. Performance evaluation of optech's altm 3100: Study on geo-referencing accuracy. In: *ION NTM*. [S.l.: s.n.], 2006. Citado 2 vezes nas páginas 23 e 38.

VALBUENA, R. et al. Patterns of covariance between airborne laser scanning metrics and lorenz curve descriptors of tree size inequality. *Canadian Journal of Remote Sensing*, Ottawa, v. 39, p. 1–14, 2013. Citado 3 vezes nas páginas 22, 23 e 33.

VAPNIK, V. *The Nature of Statistical Learning Theory*. 2nd edition. ed. New York: Springer Verlag, 1999. Citado na página 67.

WATZLAWICK, L. F.; SANQUETTA, C. R.; KIRCHNER, F. F. Gps: Ferramenta de apoio na realização de inventário florestal. *Floresta*, v. 32, n. 1, 2005. Citado 2 vezes nas páginas 23 e 39.

WESTOBY, M. et al. Plant ecological strategies: Some leading dimensions of variation between species. *Annual Review of Ecology and Systematics*, Novembro 2002. Citado na página 66.

WULDER, M.; NIEMANN, K. O.; GOODENOUGH, D. G. Local maximum filtering for the extraction of tree locations and basal area from high spatial resolution imagery. *Remote Sensing of Environment*, v. 73, p. 103–114, 2000. Citado 3 vezes nas páginas 23, 34 e 52.

YAO, W.; KRZYSZEK, P.; HEURICH, M. Tree species classification and estimation of stem volume and dbh based on single tree extraction by exploiting airborne full-waveform lidar data. *Remote Sensing of Environment*, v. 123, p. 368–380, August 2012. Citado na página 22.

ZANDONÁ, D. F.; LINGNAU, C.; NAKAJIMA, N. Y. Utilização da tecnologia lidar para obtenção de altura individual e delimitação automática de copas em povoamento de *Pinus sp.* In: INPE (Ed.). *XIII Simpósio Brasileiro de Sensoriamento Remoto*. Florianópolis, Brasil: [s.n.], 2007. p. 3693–3700. Citado na página 22.

ZANDONÁ, D. F.; LINGNAU, C.; NAKAJIMA, N. Y. Varredura a laser aerotransportado para estimativa de variáveis dendrométricas. *Scientia Forestalis*, v. 36, n. 80, p. 295–306, Dez 2008. Citado 2 vezes nas páginas 22 e 61.

ZONETE, M. F. *Análise do uso da tecnologia laser aerotransportado para inventários florestais em plantios clonais de Eucalyptus sp no sul da Bahia*. Dissertação (Mestrado) — Escola Superior de Agricultura Luiz de Queiroz, Piracicaba, 2009. Citado 4 vezes nas páginas 21, 22, 33 e 61.

